

Nr. 360

Andreas Paul

Domänenadaption zur Klassifikation von Luftbildern

Nr. 360

Domänenadaption zur Klassifikation von Luftbildern

Von der Fakultät für Bauingenieurwesen und Geodäsie
der Gottfried Wilhelm Leibniz Universität Hannover
zur Erlangung des Grades

DOKTOR-INGENIEUR (Dr.-Ing.)

genehmigte Dissertation
von

Dipl.-Ing. Andreas Paul

HANNOVER 2020

Prüfungskommission

Vorsitzender:	Prof. Dr.-Ing. Christian Heipke
Referent:	apl. Prof. Dr. techn. Franz Rottensteiner
Korreferent:	apl. Prof. Dr.-Ing. Claus Brenner
Korreferent:	Prof. Dr.-Ing. Jörn Ostermann

Tag der mündlichen Prüfung: 13.03.2020

Zusammenfassung

Flugzeuggestützte Sensorsysteme können innerhalb kurzer Zeit große Datenmengen an hoch aufgelösten Fernaufnahmen der Bodenbedeckung erfassen. Die automatische Extraktion topographischer Objekte aus diesen Luftaufnahmen anhand eines Klassifikators ist ein wichtiges Thema in der Fernerkundung. Dabei werden bei überwachten Methoden die Primitive eines zu klassifizierenden Bildes auf Basis von Bildmerkmalen durch einen Klassifikator einer vordefinierten Objektklasse zugeordnet. Das Anlernen eines solchen Klassifikators erfordert jedoch eine ausreichende Menge an qualitativ hochwertigen Trainingsdaten, deren Generierung sehr kosten- und zeitaufwändig ist. Daher ist es von hoher wirtschaftlicher Relevanz, durch die Nutzung vorhandener Trainingsdaten aus früheren Projekten (Quelldomäne) den Klassifikator auf neue Szenen (Zieldomäne) zu übertragen, ohne neue Trainingsdaten für diese Szenen generieren zu müssen. Auf dem Gebiet des maschinellen Lernens widmen sich dieser Fragestellung die Techniken des Transferlernens, wie z.B. die Domänenadaptation (DA).

Diese Arbeit stellt einen neuen Ansatz zur DA für die Klassifikation von Luftbildern von urbanen Gebieten vor, der ein verbessertes Lernen in der Zieldomäne unter Verwendung vom Wissen aus der Quelldomäne erlaubt. Dabei liegen die gelabelten Trainingsdaten nur in der Quelldomäne vor. Somit besteht das übergeordnete Ziel darin, auf den kostspieligen Aufwand zum Labeling von Trainingsdaten dank der DA verzichten zu können. Vier wesentliche Beiträge werden in der vorliegenden Arbeit zur Umsetzung des Forschungsziels geleistet. Im ersten Beitrag wird ein Ansatz zur DA auf Basis eines diskriminativen probabilistischen Klassifikators, der Logistischen Regression, entwickelt. Der initiale Klassifikator wird zunächst an den gelabelten Trainingsdaten aus der Quelldomäne angelernet. Anschließend erfolgt eine iterative Anpassung des Klassifikators an die neue Verteilung der Daten in der Zieldomäne, indem der Klassifikator an einem hybriden Trainingsdatensatz neu trainiert wird. Dabei werden Instanzen (Trainingsbeispiele) der Quelldomäne entfernt und Instanzen aus der Zieldomäne, denen ein Semi-Label ausgehend vom aktuellen Zustand des Klassifikators zugewiesen wird, dem hybriden Trainingsdatensatz hinzugefügt. Das Interesse an einem diskriminativen Ansatz ist hier durch die Annahme motiviert, dass diskriminative Ansätze gegenüber den generativen Methoden mit weniger Trainingsdaten auskommen können. Da die Anpassung des Klassifikators durch sukzessive Veränderung des Trainingsdatensatzes erfolgt, erfordert dies geeignete Strategien für die Auswahl der Trainingsinstanzen aus der Quell- und Zieldomäne, die in jeder Iteration entfernt bzw. hinzugefügt werden. Die Entwicklung einer solchen auf den Klassifikator abgestimmten Strategie stellt den zweiten Beitrag dieser Arbeit dar. Den dritten Beitrag bildet die Integration der Gewichte für Trainingsbeispiele in die Kostenfunktion der Logistischen Regression, die eine Gewichtung der Instanzen direkt beim Training des Klassifikators erlaubt. Dadurch werden zu starke abrupte Änderungen der Parameter des Klassifikators und somit der Entscheidungsgrenze vermieden. Falls die Verwendung von Quellwissen trotz aller Maßnahmen zu einer Verschlechterung des Lernens in der Zieldomäne führt, tritt ein sogenannter negativer Transfer (NT) auf. Die Entwicklung einer Strategie zur Prädiktion von NT stellt den vierten Beitrag dieser Arbeit dar.

Die Experimente anhand von fünf unterschiedlichen Testgebieten, die räumlich und zeitlich disjunkt sind, zeigen das Potential des neuen Ansatzes. Eine Auswertung ergibt, dass ein positiver Transfer zwischen verschiedenen Gebieten, deren Bilddaten sich in Bezug auf die Bebauungsstruktur der Städte, Aufnahmesensorik, Lichtverhältnisse, saisonale Effekte und Auflösung der Daten unterscheiden, möglich ist. Dabei wirken sich eine große Unähnlichkeit zwischen den Verteilungen der Daten aus beiden Domänen sowie eine starke Überlappung der Merkmalsausprägungen der einzelnen Klassen untereinander sowohl in Quell- als auch in der Zieldomäne negativ auf das Ergebnis der DA aus. Die Experimente zur Prädiktion von NT zeigen außerdem, dass es bis zu einem gewissen Grad möglich ist, Fälle von NT vorherzusagen. Dabei ist die Genauigkeit der Vorhersage auf Basis der vorgeschlagenen Strategie zur Prädiktion von NT gegenüber den alternativen Verfahren leicht im Vorteil.

Schlagerworte: Transferlernen, Domänenadaption, Negativer Transfer, Klassifikation

Abstract

Airborne sensors can capture a large amount of high resolution remotely sensed data within a short period of time. The automated extraction of topographic objects from the remotely sensed data derived by a classifier is an important topic in remote sensing. To assign pixels to a pre-defined set of classes, traditional supervised machine learning methods make predictions about unseen data using statistical models trained on a previously collected training data set. However, the generation of a sufficient amount of high quality training data for each new classification task is very costly and time consuming. Therefore, it is of high relevance to use existing training data from earlier projects (source domain) to adapt the classifier to new scenes (target domain) without having to generate new training data for these new scenes. In the field of machine learning the transfer learning techniques, such as domain adaptation, are dedicated to this type of problems.

In this thesis, a new approach for domain adaptation for the classification of urban aerial images is presented, which allows improved learning in the target domain using knowledge from the source domain. The labeled training data are only available in the source domain. The overall objective is to dispense with the costly efforts of labeling training data to classify unseen new scenes thanks to domain adaptation. Four major contributions are made in this work to implement the research objective. The first contribution is the development of an iterative approach for domain adaptation based on a discriminative probabilistic classifier, the logistic regression. The adaptation starts with the training of initial classifier on the training data set, which initially consists of the labelled source domain samples. In each further iteration a predefined number of source samples is removed from and a number of target domain samples is included into the current training data set. The target domain samples receive their semi-labels from the current state of the base classifier. The classifier will be adapted to the distribution of new data from the target domain by retraining the classifier on the current training data set. The interest in a discriminative approach is motivated by the assumption that discriminative approaches can deal with a lower number of training samples compared to generative methods. Since the classifier is adapted iteratively by modifying the training data set, the adaptation requires suitable sample selection strategies for source and target domains. The development of such a strategy tuned to the logistic regression classifier is the second contribution of this work. The third contribution is the consideration of the individual weights for each training sample, to avoid abrupt changes of the classifier and, thus, of the decision boundary. This provides more stability to the domain adaptation procedure. The weights are integrated into the cost function of the logistic regression and allow weighting the samples during the training of the classifier. If the difference of the distributions from the source and target domain is too high, the results of an adapted classifier can be degraded compared to the performance without domain adaptation. This case is referred to as negative transfer. The development of a strategy for predicting negative transfer is the fourth contribution of this paper.

The experiments based on five different urban test areas (five cities) which differ by location and acquisition time, show the potential and limitations of the new approach. The results show that

a positive transfer between images that differ with regard to the building structure of the cities, image acquisition sensors, lightning conditions and seasonal effects or geometrical resolution is possible. A high difference of the distributions from the source and target domain or a strong overlapping of the feature distributions of different classes in both the source and target domains have a negative effect on the result of the domain adaptation. The experiments also show that it is possible to reduce the amount of negative transfer using the proposed strategy for negative transfer prediction. The performance of the negative transfer prediction based on the proposed strategy is slightly better than for alternative methods tested.

Keywords: Transfer learning, domain adaptation, negative transfer, classification

Abkürzungsverzeichnis

2D	Zweidimensional
3D	Dreidimensional
CIR	Farbinfrarotdarstellung
CNN	Convolutional Neural Networks
Comp	Vollständigkeit der Klassifikation
Corr	Korrektheit der Klassifikation
CVS	Zirkuläre Validierungsstrategie
BAGGING	Bootstrap aggregating
DA	Domänenadaption
DGM	Digitales Geländemodell
DL	Deep Learning
DOM	Digitales Oberflächenmodell
DOP	Digitales Orthophoto
EM	Expectation Maximization
<i>F1</i>	<i>F1</i> -Wert der Klassifikation
GMM	Gaußsches Mischmodell
GSD	Bodenauflösung eines Pixels in Bilddaten
GT	Referenzdaten
IQR	Interquartilsabstand
ISPRS	Internationale Gesellschaft für Photogrammetrie und Fernerkundung
LGLN	Landesamt für Geoinformation und Landesvermessung Niedersachsen
LR	Logistische Regression
MAP	Maximum a-posteriori
Med.	Medianwert
ML	Maximum Likelihood
MMD	Maximum Mean Discrepancy
MW	Mittelwert
nDOM	Normalisiertes digitales Oberflächenmodell
NDVI	Normalised Difference Vegetation Index
NIR	Nahes Infrarot
NN	Nächster-Nachbar
NT	Negativer Transfer
OA	Gesamtgenauigkeit der Klassifikation
RBF	Radiale Basisfunktion
RF	Randomisierte Entscheidungsbäume
RKHS	Hilbertraum mit reproduzierendem Kern
RGB	Rot-Grün-Blau
ROC	Grenzwertoptimierungskurve
Std	Standardabweichung
SVM	Support Vector Machine
TL	Transferlernen
TOP	Digitales True Orthophoto

Liste von Symbolen

Allgemein

a	Skalar
\mathbf{b}	Vektor
j, l, n, κ	Indizes
\exp	Exponentialfunktion
\ln	natürlicher Logarithmus
μ	Mittelwert
σ	Standardabweichung
$\mathbb{1}[\cdot]$	Indikatorfunktion
\mathbf{I}	Einheitsmatrix
\propto	Proportionalität

Klassifikation

\mathbf{x}	Merkmalsvektor
\mathcal{X}	Merkmalsraum
y	Klassenlabel
\mathcal{Y}	Objektraum bzw. Menge der Klassenlabel
C^κ	Ein diskreter Klassenlabel aus \mathcal{Y}
\overline{TD}	Trainingsdatensatz
(\mathbf{x}_n, y_n)	Ein Trainingsbeispiel im \overline{TD}
N	Anzahl der Trainingsbeispiele in \overline{TD}
K	Anzahl diskreter Klassenlabels
$f(\cdot)$	Entscheidungsfunktion bzw. Klassifikator
$p(\cdot)$	Wahrscheinlichkeit
$\Phi(\cdot)$	Abbildungsfunktion zur Transformation der Merkmalsvektoren
M	Dimension des transformierten Merkmalsraums
\mathbf{w}	Parametervektor der Logistischen Regression
$t_{n\kappa}$	Indikatorvariable für ein Trainingsbeispiel n aus \overline{TD} und ein Klassenlabel C^κ
$E(\cdot)$	Kostenfunktion bzw. Errorfunktion des Klassifikators
\mathbf{H}	Hesse Matrix
τ	Iteration der Newton-Raphson Optimierung
$\text{sig}(\cdot)$	Logistische Sigmoidfunktion

Domänenadaption

S	Quelle (en: <i>source</i>); kommt auch als Index vor
T	Ziel (en: <i>target</i>); kommt auch als Index vor
$\mathcal{D}_S, \mathcal{D}_T$	Quell- bzw. Zieldomäne
$\mathcal{T}_S, \mathcal{T}_T$	Quell- bzw. Zielaufgabe
$f_T(\cdot)$	Zielfunktion zur Prädiktion der Labels in \mathcal{D}_T
i	Laufindex für einen Domänenadaptionsschritt (Iteration)
\overline{TD}_h^i	Aktueller Trainingsdatensatz in der Iteration i
$\mathbf{x}_{\overline{TD}_h^i, n}$	Ein Merkmalsvektor in \overline{TD}_h^i
$y_{\overline{TD}_h^i, n}$	Klassenlabel des Merkmalsvektors $\mathbf{x}_{\overline{TD}_h^i, n}$ in \overline{TD}_h^i
$g_{\overline{TD}_h^i, n}$	Gewicht des Merkmalsvektors in \overline{TD}_h^i
ρ_S	Anzahl pro Klasse der aus \overline{TD}_h^i zu eliminierenden Trainingsbeispiele der \mathcal{D}_S
ρ_T	Anzahl pro Klasse der zu \overline{TD}_h^i hinzuzufügenden Trainingsbeispiele der \mathcal{D}_T
$y_{S, l}^{LR}$	Referenzlabel einer Stichprobe aus \mathcal{D}_S
$\tilde{y}_{S, l}^{LR}$	Label einer Stichprobe aus \mathcal{D}_S , das mit der LR ermittelt wurde
$\tilde{y}_{T, q}^{LR}$	Semi-Label einer Stichprobe aus \mathcal{D}_T , das mit der LR ermittelt wurde
$\tilde{y}_{T, q}^{k-NN}$	Semi-Label einer Stichprobe aus \mathcal{D}_T , das mit der NN-Analyse ermittelt wurde
RW	Parameter für die Rasterweite bei der systematischen Stichprobenentnahme
$\mathcal{Q}(\cdot)$	Bewertungsfunktion für Auswahl der auszutauschenden Trainingsbeispiele
$d_B(\mathbf{x})$	Distanzmaß für Abstand eines Merkmalsvektors \mathbf{x} zur Entscheidungsgrenze
k	Anzahl der Nachbarn für die k -NN Analyse
γ	Parameter der Gewichtsfunktion zur Ermittlung $g_{\overline{TD}_h^i, n}$
i_{max}	Parameter für die Anzahl der Iterationen bei Anpassung der Gewichte
$g_{S, max}$	Maximales Gewicht eines Trainingsbeispiels aus \mathcal{D}_S während der Anpassung
$g_{T, max}$	Maximales Gewicht eines Trainingsbeispiels aus \mathcal{D}_T während der Anpassung
$\mathbf{x}_S, \mathbf{x}'_S$	Zwei unabhängige Stichprobenmengen aus \mathcal{D}_S zur Messung der MMD
$\mathbf{x}_T, \mathbf{x}'_T$	Zwei unabhängige Stichprobenmengen aus \mathcal{D}_T zur Messung der MMD
$\mathbf{x}_{S, new}, \mathbf{x}'_{S, new}$	Stichprobenmengen $\mathbf{x}_S, \mathbf{x}'_S$ nach Modifikation der Verteilung
$\mathbf{x}_{T, new}, \mathbf{x}'_{T, new}$	Stichprobenmengen $\mathbf{x}_T, \mathbf{x}'_T$ nach Modifikation der Verteilung
\tilde{N}	Anzahl der Stichproben in $\mathbf{x}_S, \mathbf{x}'_S, \mathbf{x}_T, \mathbf{x}'_T$ und $\mathbf{x}_{S, new}, \mathbf{x}'_{S, new}, \mathbf{x}_{T, new}, \mathbf{x}'_{T, new}$
d_{MMD}	Domänendistanz auf Basis der MMD
d_{MMD_m}	Domänendistanz auf Basis der MMD nach Modifikation der Verteilungen
λ	Parameter für die Verschiebung einer Verteilung zur Messung der MMD
τ_{MMD_m}	Schwellwertparameter zur Prädiktion von NT

Inhaltsverzeichnis

1	Einleitung	13
1.1	Motivation und Problemstellung	13
1.2	Ziel und wissenschaftlicher Beitrag der Arbeit	16
1.3	Aufbau der Arbeit	18
2	Grundlagen	19
2.1	Klassifikation von Bildern	19
2.1.1	Logistische Regression	21
2.2	Transferlernen	25
2.2.1	Definitionen und Notation	25
2.2.2	Domänenadaption	26
2.2.3	Negativer Transfer	28
2.3	Maximum Mean Discrepancy	29
3	Stand der Forschung	33
3.1	Domänenadaption	33
3.1.1	Verwandte Problemstellungen	34
3.1.2	Überwachte Domänenadaption	35
3.1.3	Semi-überwachte Domänenadaption	38
3.1.4	Unüberwachte Domänenadaption	45
3.1.5	Deep Domain Adaptation	45
3.1.6	Umgang mit negativem Transfer	46
3.2	Diskussion	50
4	Methodik	53
4.1	Konzept der iterativen Anpassung	53
4.2	Basisklassifikator: Logistische Regression	55
4.2.1	Gewichtung der Trainingsbeispiele	55
4.2.2	Regularisierung	57
4.3	Domänenadaption	58
4.3.1	Ablauf der Domänenadaption	59
4.3.2	Auswahl der Instanzen	62
4.3.3	Strategie zur Gewichtung der Trainingsbeispiele	67
4.4	Prädiktion von negativem Transfer	70
4.5	Diskussion	73
5	Aufbau der Experimente	77
5.1	Testgebiete	77
5.2	Allgemeiner Untersuchungsablauf	79
5.3	Kriterien für die Bewertung	81
5.4	Evaluierung der Domänenadaption	85
5.5	Merkmale	86

6 Experimente	93
6.1 Parameter	93
6.1.1 Parameter des Klassifikators	93
6.1.1.1 Zielsetzung	93
6.1.1.2 Durchführung der Experimente	94
6.1.1.3 Ergebnisse	96
6.1.2 Parameter der Domänenadaption	97
6.1.2.1 Zielsetzung	97
6.1.2.2 Durchführung der Experimente	98
6.1.2.3 Ergebnisse	99
6.1.3 Analyse der Parametereinstellungen	105
6.2 Analyse der Prädiktion von negativem Transfer	108
6.2.1 Verbesserung der Qualität der Prädiktion	108
6.2.1.1 Zielsetzung	108
6.2.1.2 Durchführung der Experimente	108
6.2.1.3 Ergebnisse	109
6.2.2 Vergleich mit alternativen Verfahren	110
6.2.2.1 Zielsetzung	110
6.2.2.2 Durchführung der Experimente	111
6.2.2.3 Ergebnisse	112
6.2.3 Schwellwert zur Prädiktion von negativem Transfer	113
6.2.3.1 Zielsetzung	113
6.2.3.2 Durchführung der Experimente	113
6.2.3.3 Ergebnisse	115
6.2.4 Diskussion	116
6.3 Evaluierung der Domänenadaption	117
6.3.1 Zielsetzung	117
6.3.2 Durchführung der Experimente	117
6.3.3 Allgemeine Darstellung der Ergebnisse	119
6.3.4 Datensatzspezifische Ergebnisse	124
6.3.5 Analyse der Ergebnisse nach Testgebieten	143
6.3.6 Untersuchung zur Einbeziehung von lokalem Kontext	147
6.3.7 Diskussion	150
6.4 Klassifikationsergebnisse nach Prädiktion von negativem Transfer	152
6.4.1 Zielsetzung	152
6.4.2 Durchführung der Experimente	152
6.4.3 Ergebnisse	153
6.4.4 Diskussion	160
6.5 Vergleich mit Standardverfahren	162
6.5.1 Zielsetzung	162
6.5.2 Durchführung der Experimente	163
6.5.3 Ergebnisse	164
7 Zusammenfassung und Ausblick	167
Literaturverzeichnis	173

1 Einleitung

1.1 Motivation und Problemstellung

Die Extraktion von topographischen Objekten aus Luft- und Satellitenbildern ist seit vielen Jahren ein wichtiges Thema in der Photogrammetrie und Fernerkundung. Mit der Entwicklung der digitalen Technik und verschiedener Sensorsysteme konnten in den letzten Jahren umfangreiche, überregionale und hochauflösende Multispektralbilder produziert werden. Durch die ständig produzierte Datenmenge kann die Aufgabe der semantischen Bildauswertung mittlerweile nur mit einem sehr großen Aufwand oder unter gewissen Einschränkungen manuell bewältigt werden. Damit begann eine rasante Verbreitung der Methoden des maschinellen Lernens zur automatischen Klassifikation von Luft- und Satellitenbildern. Die Klassifikation bezeichnet in diesem Zusammenhang einen Vorgang zur Extraktion von semantischen Informationen aus den Bilddaten. Bei der Klassifikation wird jedes Pixel eines Bildes oder jeder Punkt einer Punktwolke einer vordefinierten Klasse, die einer Objektart entspricht, zugeordnet [Rottensteiner, 2017]. Um die Klassifikation eines Bildes durchführen zu können, muss der Zusammenhang zwischen den Bilddaten und der jeweiligen Objektart durch einen Klassifikator zuerst erlernt werden. Um diesen Zusammenhang herzustellen, werden die Objekte bei statistischen Methoden der Bildanalyse durch statistische Eigenschaften der Sensordaten beschrieben. Beim überwachten Lernen wird ein Klassifikator an einem Satz von gelabelten Trainingsdaten angelernet, welcher eine Menge an Pixeln enthält, deren Objektart (Klasse) bekannt ist.

Herkömmliche überwachte Klassifikationsmethoden spielen eine wichtige Rolle in der Fernerkundung. Solche Methoden treffen die Annahme, dass Trainingsdaten und die zu klassifizierenden Testdaten denselben Merkmalsraum und dieselbe Verteilung der Daten im Merkmalsraum teilen, wobei die Trainingsdaten für die vorliegende Verteilung repräsentativ sind. Anschließend kann ein einmal antrainierter überwachter Klassifikator auf beliebige Testdaten ohne große Genauigkeitseinbuße angewendet werden, solange die Testdaten diese Annahme erfüllen. Das Training eines komplexen Modells mit hoher Genauigkeit erfordert jedoch große Mengen an qualitativ hochwertigen Trainingsdaten, die oft manuell erzeugt werden müssen. In den Fernerkundungsdaten kann die zugrunde liegende Annahme der herkömmlichen überwachten Klassifikatoren jedoch bereits durch veränderte Sensorcharakteristik, Beleuchtungsverhältnisse oder saisonale Effekte während der Aufnahme verletzt werden. Damit hängt die Fähigkeit von überwachten Klassifikationsmethoden zur Anpassung an neue Szenen und Aufgaben in der Fernerkundung von der Verfügbarkeit von Trainingsdaten ab. Die Generierung und Bereitstellung einer ausreichenden Menge an solchen Trainingsdaten ist jedoch sehr kosten- und zeitaufwändig. Daher ist es von

hoher wirtschaftlicher Relevanz, durch die Nutzung vorhandener Trainingsdaten aus früheren Projekten den Klassifikator ohne oder mit nur wenigen Trainingsdaten auf neue Szenen umzulernen: Es findet Wissenstransfer statt. Auf dem Gebiet des maschinellen Lernens widmet sich dieser Fragestellung das *Transferlernen* (TL) [Thrun und Pratt, 1998; Pan und Yang, 2010].

Beim TL geht man von zwei Domänen aus: einer Quelldomäne, in der eine relativ große Menge an vorhandenen Trainingsdaten, z.B. aus früheren Projekten, vorliegt und einer Zieldomäne mit neu zu klassifizierenden Testdaten, in der nur wenige oder gar keine Trainingsdaten zur Verfügung stehen. Jede Domäne wird durch ein Merkmalsraum und eine Verteilung der Merkmalsvektoren in diesem Raum beschrieben. In jeder Domäne ist eine Lernaufgabe zu lösen, die durch eine Menge von Klassenlabels und eine Entscheidungsfunktion zur Prädiktion dieser Labels aus den Merkmalsvektoren definiert wird. Der hier verfolgte Ansatz gehört zu einer Unterkategorie des TL, die *Domänenadaption* (DA) genannt wird. Dabei wird davon ausgegangen, dass Quell- und Ziellernaufgabe identisch und die Domänen unterschiedlich sind [Pan und Yang, 2010]. Das zugehörige Modell der DA in dieser Arbeit setzt voraus, dass die Szenen in beiden Domänen sich durch die gemeinsame Verteilung der Merkmalsvektoren und der zugehörigen Klassenlabels unterscheiden [Tuia et al., 2016]. Das impliziert, dass diese Unterschiede sowohl durch die Verteilung der Merkmalsvektoren als auch der a-posteriori Wahrscheinlichkeiten der Klassenlabels bei gegebenen Daten hervorgerufen werden können. Ziel der DA ist ein verbessertes Lernen in der Zieldomäne unter Verwendung vom Wissen aus der Quelldomäne. Die vorliegende Arbeit nimmt sich außerdem vor, ohne gelabelte Daten in der Zieldomäne auszukommen. Dies entspricht einer semi-überwachten DA [Tuia et al., 2016]. Somit besteht das übergeordnete Ziel darin, auf den kostspieligen Aufwand zum Labeling von Trainingsdaten dank der DA verzichten zu können. Eine gewisse Ähnlichkeit der Domänen ist dabei die notwendige Voraussetzung für einen erfolgreichen Wissenstransfer. Ist diese Ähnlichkeit nicht gegeben, kann es zur Situation kommen, in der die Verwendung vom Quellwissen das Lernen in der Zieldomäne verschlechtern würde: Ein sogenannter *negativer Transfer* (NT) tritt auf. Typische Beispiele für die Anwendung der DA im Bereich der Fernerkundung sind in Anlehnung an [Tuia et al., 2016] schematisch in Abbildung 1.1 vorgestellt.



Abbildung 1.1: Beispiele zur Anwendung der DA im Bereich der Fernerkundung, in denen eine Adaption angewendet werden kann, um ein existierendes Modell auf neue Bildaufnahmen zu übertragen: bei räumlich disjunkten Szenen aus einem Interessengebiet, dessen Aufnahmen zeitlich disjunkt sein können (links); bei Mosaiken mit teilweise Überschneidung der Bilder aus einem Interessengebiet, wobei die Aufnahmen zeitlich disjunkt sein können (in der Mitte); bei Szenen aus verschiedenen Gebieten, die räumlich und/oder zeitlich disjunkt sind (rechts). In allen drei Fällen können die Bildaufnahmen unterschiedliche Charakteristika aufweisen. Gelabelte Daten liegen nur in rot markierten Bereichen vor (Eigene Darstellung in Anlehnung an [Tuia et al., 2016]).

Grundsätzlich findet sich eine Vielzahl von Ansätzen, die sich mit der DA in der Fernerkundung beschäftigen. Eine weit verbreitete Gruppe von Verfahren basiert auf Transfer der Merkmalsrepräsentationen, um eine gegenüber den Veränderungen in den beiden Domänen invariante Repräsentation zu finden [Pan und Yang, 2010]. Beispielsweise wird angenommen, dass unter den vorhandenen Merkmalen in den beiden Domänen einige Merkmale existieren, die bereits gegen diese Unterschiede invariant sind [Bruzzone und Persello, 2009; Persello und Bruzzone, 2016]. Diese Gruppe von Methoden ist vor allem für Hyperspektralbilder mit vielen einzelnen Bändern verbreitet. Andere gehen davon aus, dass eine Transformation in einen latenten gemeinsamen Merkmalsraum gefunden werden kann, in dem die Domänen möglichst ähnlich sind, wie z.B. in [Tuia et al., 2014; Yang und Crawford, 2016]. Das Ziel ist dabei, die gemeinsame Verteilung der Daten und der zugehörigen Klassen aus beiden Domänen einander näher zu bringen.

Mit Hilfe von Verfahren zum Transfer von Instanzen kann die Komplexität des DA-Ansatzes relativ klein gehalten werden. Eine Stärke dieser Verfahren liegt darin, dass zur Anpassung eines Klassifikators ausschließlich die Instanzen (Trainingsamples) aus der jeweiligen Domäne verwendet werden. Im Bereich der Fernerkundung sind Verfahren zur DA basierend auf Transfer von Instanzen z.B. für überwachte DA (gelabelte Daten in Quell- und Zieldomäne) [Dai et al., 2007; Li et al., 2017] und semi-überwachte (gelabelte Daten nur in Quelldomäne) DA [Bruzzone und Marconcini, 2010; Sun et al., 2013] verwendet worden. Es wurden dabei Ansätze, die von einem Gaußschen Mischmodell als Modell für die Verteilung der Daten ausgehen [Bruzzone und Prieto, 2001; Bahirat et al., 2012], Ansätze auf Basis von Kernel-Methoden [Bruzzone und Marconcini, 2010; Sun et al., 2013], auf Basis der Logistischen Regression [Zhang et al., 2010] oder auf Basis von Boosting [Dai et al., 2007] entwickelt.

Die Kernidee hinter dem Transfer von Instanzen zur semi-überwachten DA liegt darin, den anhand der Quelldaten angelernten Klassifikator sukzessive an die Verteilung der Daten in der Zieldomäne anzupassen. Der Klassifikator wird also zunächst an einem Trainingsdatensatz angelernt, welcher nur gelabelte Trainingsbeispiele aus der Quelldomäne enthält. Dann werden die gelabelten Trainingsbeispiele aus der Quelldomäne in dem Trainingsdatensatz sukzessive gelöscht und Trainingsbeispiele aus der Zieldomäne hinzugefügt, denen ein Label („*Semi-Label*“) ausgehend von dem aktuellen Zustand des Klassifikators zugewiesen wird. Anschließend wird der Klassifikator auf dem aktuellen Trainingsdatensatz neu trainiert. Auf diese Weise erfolgt eine iterative Anpassung des Klassifikators an die Verteilung der Daten aus der Zieldomäne, die von einer iterativen Transformation der Entscheidungsgrenze begleitet wird. Dies impliziert, dass die Trainingsbeispiele für den Trainingsdatensatz sorgfältig ausgewählt werden sollten. Am Ende besteht der Trainingsdatensatz nur aus den semi-gelabelten Trainingsbeispielen aus der Zieldomäne. Sobald die Adaption konvergiert hat, findet die abschließende Klassifikation der Zieldaten mit dem zuletzt angelernten Klassifikator statt.

Eine ähnliche Strategie wurde für die DA zwischen zwei zeitlich disjunkten Bilddaten in [Bruzzone und Marconcini, 2010] erfolgreich eingesetzt. Dabei verwenden Bruzzone und Marconcini [2010] eine Support Vector Machine als Basisklassifikator. Im Kontext der vorliegenden Aufgabe erscheint jedoch dies keine optimale Wahl zu sein. Es wird hier davon ausgegangen, dass ein diskriminativer, probabilistischer Klassifikator, wie Logistische Regression, zur DA zwischen zeitlich und/oder räumlich disjunkten Szenen mit einem relativ kleinen Stichprobenumfang besser

geeignet ist. Die beiden Klassifikatoren können laut [Musa, 2013] eine vergleichbare Genauigkeit erzielen. Dafür ist die Logistische Regression wegen niedrigerer Rechenkomplexität schneller, kann auf Mehrklassenprobleme unmittelbar erweitert werden und liefert einen leichter interpretierbaren (probabilistischen) Output. Die Logistische Regression wurde für die DA in [Zhang et al., 2010] und [Seah et al., 2013] eingesetzt, wobei die Autoren von mehreren verfügbaren Quelldomänen ausgehen, in denen gelabelte Daten zur Verfügung stehen. Beide Ansätze verfolgen dabei die Strategie, den Klassifikator durch Umgewichtung der Trainingsbeispiele aus den vorliegenden Quelldomänen an die Verteilung der Daten in der Zieldomäne anzupassen. Es kommen dabei keine Semi-Labels zum Einsatz. Zudem wurden die Ansätze aus [Zhang et al., 2010; Seah et al., 2013] nicht auf Fernerkundungsdaten getestet.

Eine Schwachstelle der semi-überwachten Ansätze zur DA ist die Validierung des Adaptionprozesses zur Vermeidung von NT. Dabei ist der NT im wesentlichen auf starke Unterschiede (fehlende Ähnlichkeit) zwischen der Quell- und Zieldomäne zurückzuführen [Rosenstein et al., 2005]. Eine effektive Feststellung solcher Unterschiede wird durch die fehlenden Labels in der Zieldomäne erschwert. Einige Verfahren versuchen deswegen, den NT bereits während der Adaption zu vermeiden [Yao und Doretto, 2010; Seah et al., 2013; Persello und Bruzzone, 2016], treffen jedoch keine Aussage darüber, ob die Adaption erfolgreich war. Eine Methode, die eine solche Aussage ermöglicht, basiert auf der Strategie zur zirkulären Validierung [Bruzzone und Marconcini, 2010]. Sie basiert jedoch auf einer Heuristik, die nicht immer zutrifft und führt deswegen oft zu einer falschen Prädiktion. Dies kann umgegangen werden, indem man nichtparametrische Funktionen, wie Maximum Mean Discrepancy, zur Messung der Ähnlichkeit zwischen zwei Domänen einbezieht. Maximum Mean Discrepancy ist ein generisches Maß für die Ähnlichkeit zweier Verteilungen als Abstand zwischen den Mittelwerten von deren Wahrscheinlichkeitsverteilungen, deren Messung keine Labels in den beiden Domänen erfordert. Methoden auf Basis der Maximum Mean Discrepancy wurden für die DA in der Fernerkundung z.B. zur Gewichtung von Instanzen während der Adaption [Matasci et al., 2015; Sun et al., 2016] oder im Kontext einer Vermeidungsstrategie vom NT zur Auswahl von ähnlichen Quellen eingesetzt [Vogt et al., 2018]. Die Verwendung der Maximum Mean Discrepancy zur Prädiktion von NT wurde jedoch bisher kaum untersucht. Zudem wird im Rahmen dieser Arbeit vorgeschlagen, die a-posteriori Wahrscheinlichkeiten der Klassenlabels bei gegebenen Daten aus der Quelldomäne in die Schätzung der Distanzmetrik auf Basis der Maximum Mean Discrepancy einzubeziehen, um ein besseres Merkmal zur Prädiktion von NT zu erzeugen.

1.2 Ziel und wissenschaftlicher Beitrag der Arbeit

Das Ziel dieser Arbeit ist die Entwicklung einer Methode zur DA für die Klassifikation von Luftbildern, um den Umfang der dafür nötigen Trainingsdaten zu reduzieren. Der wesentliche wissenschaftliche Beitrag lässt sich wie folgt zusammenfassen:

- **Entwicklung eines neuen Ansatzes zur DA auf Basis eines diskriminativen probabilistischen Klassifikators.** In dieser Arbeit wird ein iterativer semi-überwachter DA-Ansatz

zur Anpassung des Klassifikators an die Verteilung der Zieldaten entwickelt, der ein Wissenstransfer zwischen räumlich und/oder zeitlich disjunkten Szenen erlaubt. Der iterative Algorithmus wurde von Bruzzone und Marconcini [2010] inspiriert, die jedoch eine Support Vector Machine als Basisklassifikator verwenden. In dieser Arbeit wird ein diskriminativer Ansatz auf Basis der *Logistischen Regression* als Basisklassifikator eingesetzt. Die Logistische Regression hat den Vorteil, dass sie die Klassenzugehörigkeit direkt anhand der a-posteriori Wahrscheinlichkeiten für Objektklassen bei gegebenen Daten liefert. Außerdem weist die Logistische Regression geringere Rechenkomplexität auf, sie ist schneller und kann auf einfache Weise auf Mehrklassenprobleme angewandt werden. Das Interesse an einem diskriminativen Ansatz ist zusätzlich durch die Annahme motiviert, dass diskriminative Ansätze gegenüber den generativen Methoden aufgrund der Art der Modellierung der a-posteriori Wahrscheinlichkeiten mit weniger Trainingsdaten auskommen können [Bishop, 2006]; diese Aussage wird im Rahmen der Experimente exemplarisch untersucht. Es wird hier deswegen davon ausgegangen, dass die Logistische Regression zur DA zwischen zeitlich und/oder räumlich disjunkten Szenen, in denen keine Trainingsdaten in der Zieldomäne vorliegen, besser geeignet ist. Zudem sind die DA-Ansätze auf Basis der diskriminativen probabilistischen Klassifikatoren in der Literatur kaum untersucht worden. Die Ausnahme bilden die Arbeiten von Zhang et al. [2010] und Seah et al. [2013]. Diese gehen jedoch, wie oben bereits erwähnt, von anderen Voraussetzungen aus.

- **Entwicklung der an den Klassifikator angepassten Strategien zur Auswahl von auszutauschenden Instanzen im DA Prozess.** Aufgrund des im Vergleich zu [Bruzzone und Marconcini, 2010] unterschiedlichen Trainingsparadigmas des Klassifikators müssen andere Strategien zur Auswahl der auszutauschenden Trainingsbeispiele für die DA entwickelt werden. In jeder Iteration wird der Klassifikator anhand eines hybriden Trainingsdatensatzes trainiert und auf diese Weise schrittweise an die zu klassifizierende Verteilung angepasst. Außerdem wird bei der Logistischen Regression im Unterschied zu Support Vector Machines jede Instanz beim Training berücksichtigt. Eine erfolgreiche Adaption erfordert damit geeignete und wohl überlegte Strategien für Trainingsinstanzen aus der Quell- und Zieldomäne, die in dem hybriden Trainingsdatensatz entfernt bzw. hinzugefügt werden. Als Basis für das Auswahlkriterium für die Daten aus der Quelldomäne dient weiterhin, wie in [Bruzzone und Marconcini, 2010], ein Distanzmaß zur Entscheidungsgrenze. Statt diese Distanz in einem mehrdimensionalen Raum zu berechnen, wird hier allerdings direkt der probabilistische Output zur Bestimmung einer solchen Distanz verwendet. Damit werden die Trainingsbeispiele, die näher an die Entscheidungsgrenze liegen, erst in späteren Iterationen aus dem Trainingsdatensatz gelöscht, um eine abrupte Änderung der Parameter (Entscheidungsgrenze) zu vermeiden. Bei der Auswahl der Trainingsdaten aus der Zieldomäne kommt auch eine Clusteranalyse zum Einsatz, die lokale Besonderheiten von Verteilungen berücksichtigt.
- **Entwicklung einer Strategie zur Gewichtung der Trainingsbeispiele im DA Prozess.** Jede Instanz in dem aktuellen Trainingsdatensatz übt bei der herkömmlichen Logistischen Regression eine gewisse Wirkung auf die Lage der Entscheidungsgrenze aus. In dieser Arbeit wird ein zusätzliches Gewicht für jede Instanz in dem Trainingsprozess eingeführt, um eine zu plötzliche, abrupte Änderung der Parameter der Entscheidungsgrenze beim Austausch von Instanzen zu vermeiden. Die Gewichte werden dabei direkt in die Kostenfunktion der

Logistischen Regression integriert. Nach bestem Wissen des Autors liegen in der Literatur bislang keine Verfahren auf Basis der Logistischen Regression vor, die Gewichte direkt in die Kostenfunktion integrieren.

- **Entwicklung einer Strategie zur Prädiktion von NT.** Der NT ist im Wesentlichen auf starke Unterschiede in den Verteilungen der Daten zurückzuführen. Um solche Unterschiede effektiv feststellen zu können, braucht man gelabelte Daten in beiden Domänen. Alternativen, die keine Labels in der Zieldomäne brauchen, greifen z.B. auf die Verteilungen der Daten zu [Vogt et al., 2018] oder auf spezielle Strategien, die nur eine Auswertung auf der Quelldomäne erfordern [Bruzzone und Marconcini, 2010]. Diese alternativen Lösungen sind jedoch entweder nicht zur Prädiktion von NT konzipiert oder basieren auf Heuristiken, die nicht immer zutreffen. In Rahmen dieser Arbeit wird ein Maß für die Ähnlichkeit zweier Domänen auf Basis der *Maximum Mean Discrepancy* Metrik zur Prädiktion von NT entwickelt. Zudem wird im Rahmen dieser Arbeit vorgeschlagen, die a-posteriori Wahrscheinlichkeit der Klassen aus der Quelldomäne in die Berechnung der Distanzmetrik auf Basis der Maximum Mean Discrepancy einzubeziehen.

Dem vorgestellten Ansatz liegen zwei Forschungshypothesen zugrunde, die in Rahmen dieser Arbeit überprüft werden. Für die DA wird angenommen, dass einerseits eine Anpassung des ausgewählten Klassifikators an eine vorgegeben Zieldomäne ohne zusätzliche Trainingsdaten möglich ist und andererseits der Genauigkeitsverlust durch die DA gegenüber der unmittelbaren Nutzung eines anhand der gelabelten Zieldaten angelernten Klassifikators relativ klein gehalten werden kann. Dabei muss die Bedingung erfüllt sein, dass die Verteilungen der Daten aus der Quell- und Zieldomäne ähnlich genug sind. Die zweite Forschungshypothese bezieht sich auf diese Ähnlichkeit und die Prädiktion von NT. Es wird davon ausgegangen, dass die Fälle von NT mit hoher Wahrscheinlichkeit aus der Verteilung der Daten mit der vorgeschlagenen Strategie vorhergesagt werden können. Die Hypothesen werden im Rahmen von Experimenten anhand von realen Datensätzen aus fünf unterschiedlichen Testgebieten, die städtische Gebiete zeigen, evaluiert. Die Testgebiete sind untereinander räumlich disjunkt und haben unterschiedliche Aufnahmezeiten, die Städte haben unterschiedliche Bebauungsstruktur und Grad der Urbanisierung, die Aufnahmen der Testgebiete weisen aufgrund der verschiedenen Bildflugzeiten unterschiedliche Beleuchtungsverhältnisse und saisonale Effekte (z.B. Ausprägung der Vegetation und Belaubung der Bäume) auf. Damit stellen sie eine gute Grundlage zur Evaluierung der DA dar.

1.3 Aufbau der Arbeit

Die Arbeit gliedert sich in sieben Kapitel. Im Kapitel 2 werden wesentliche Grundlagen aus dem Bereich der Bildanalyse und des maschinellen Lernens vorgestellt. Im darauf folgenden Kapitel 3 wird ein Überblick über den aktuellen Stand der Forschung zur Domänenadaptation präsentiert. Das Kapitel 4 widmet sich der Beschreibung des entwickelten Ansatzes zur Domänenadaptation. Die Testdaten und die Strategie zur Evaluierung werden in Kapitel 5 beschrieben. In Kapitel 6 wird der entwickelte Ansatz anhand einer experimentellen Untersuchungen auf realen Daten evaluiert. Die Arbeit endet mit einer Zusammenfassung und einem Ausblick in Kapitel 7.

2 Grundlagen

In diesem Kapitel werden die Grundlagen für die Domänenadaption und die Erkennung von negativem Transfer vorgestellt, die für weitere Betrachtungen innerhalb dieser Arbeit erforderlich sind. Die Darstellung beginnt mit einer kurzen Einführung in die Aufgabe der Klassifikation von Bildern in Kapitel 2.1. Die allgemeinen Grundlagen und Konzepte des Transferlernens inklusive der Domänenadaption und des Phänomens des negativen Transfers werden in Kapitel 2.2 vorgestellt. Schließlich beschäftigt sich das Kapitel 2.3 mit den Grundlagen der Maximum Mean Discrepancy zur Messung der Ähnlichkeit zweier Verteilungen aus unterschiedlichen Domänen.

2.1 Klassifikation von Bildern

Die Klassifikation von Luft- und Satellitenbildern ist ein wichtiges Werkzeug in der Fernerkundung, welches eine semantische Interpretation der Szene erlaubt. Die Interpretation der Szenen braucht das 'Wissen' über die Objekte selbst. Nach Art der Wissensrepräsentation unterscheidet man zwischen *modellbasierten* und *statistischen* Methoden der Bildanalyse, wobei die Objekte in der jeweiligen Art durch Modelle bzw. durch statistische Eigenschaften der Sensordaten in Bezug auf diese Objekte beschrieben werden. Diese Arbeit konzentriert sich weiterhin auf statistischen Methoden der Bildanalyse. Im Rahmen einer Klassifikation werden Merkmale der Bildprimitive mit dem Ziel analysiert, diesem Bildprimitiv eine Objektklasse zuzuordnen. Als Bildprimitive werden dabei die zu klassifizierenden Einheiten im Bild, z.B. Segmente oder Pixel, bezeichnet und Merkmale sind charakteristischen Eigenschaften der Bildprimitive. Als Bildprimitive agieren in dieser Arbeit Pixel, somit beschreiben die Merkmale unterschiedliche Charakteristika der jeweiligen Pixel. Die Menge der Merkmale eines Pixels wird in einem Merkmalsvektor \mathbf{x} zusammengefasst. Die Merkmale spannen einen Merkmalsraum \mathcal{X} auf, in dem die Analyse der Bildprimitive stattfindet. Dabei wird davon ausgegangen, dass die Pixel gleicher Objektart ähnliche Merkmale aufweisen. Formal ausgedrückt besteht die Aufgabe der Klassifikation darin, einem Merkmalsvektor $\mathbf{x} \in \mathcal{X}$ ein diskretes Klassenlabel $y \in \mathcal{Y}$ zuzuweisen, welches ein Objektart aus dem Bild beschreibt, wobei \mathcal{Y} die Menge der Klassenlabels darstellt. Die dafür zuständige Abbildungsfunktion $f : \mathcal{X} \rightarrow \mathcal{Y}$ wird beim Training gelernt und als Entscheidungsfunktion bzw. Klassifikator bezeichnet. Ihr Funktionswert bestimmt das Klassenlabel als Funktion des zugehörigen Merkmalsvektors \mathbf{x} : $y = f(\mathbf{x})$.

Überwachte und unüberwachte Lernverfahren. Je nachdem, ob gelabelte Daten beim Training zur Verfügung stehen oder nicht, unterscheidet man bei den statistischen Methoden der Bildana-

lyse zwischen *überwachten* und *unüberwachten* Lernverfahren [Bishop, 2006]. Beim überwachten Lernen wird ein Klassifikator an einem Satz von gelabelten Trainingsdaten \overline{TD} angelernt, $\overline{TD} \subseteq (\mathcal{X} \times \mathcal{Y})$. Dabei steht dem n -ten Pixel aus dem Trainingsdatensatz \overline{TD} der Größe N bei den pixelbasierten Verfahren eine entsprechende Objektklasse $y_n \in \mathcal{Y}$ zur Verfügung. Alle Merkmale eines Pixels werden zu einem Merkmalsvektor \mathbf{x}_n zusammengefasst. Damit lässt sich ein Trainingsdatensatz wie folgt beschreiben: $\overline{TD} = \{(\mathbf{x}_n, y_n)\}_{n=1}^N$, wobei ein Tupel (\mathbf{x}_n, y_n) ein *Trainingsbeispiel* aus der Menge der Trainingsdaten beschreibt. Der Unterschied der unüberwachten zu den überwachten Methoden liegt in der Zusammensetzung des Trainingsdatensatzes. Beim unüberwachten Lernen liegen nur ungelabelte Daten in Form von Merkmalsvektoren für das Training vor, es sind also keine Vorinformationen über die zugehörigen Objektklassen gegeben. Damit besteht ein Trainingsdatensatz in diesem Fall nur aus (ungelabelten) *Trainingsmerkmalen*: $\overline{TD} = \{(\mathbf{x}_n)\}_{n=1}^N$. Verfahren dieser Gruppe gehen beim Training von einem gewissen Zusammenhang zwischen den Merkmalsrepräsentationen einer Klasse aus, die sogenannte Cluster (Ballungen) im Merkmalsraum bilden. Die Zuordnung der Cluster zu den einzelnen Klassen erfordert bei unüberwachten Verfahren eine Benutzerinteraktion bzw. zusätzliches Wissen über die Ausprägung der Objekte in den Daten.

Probabilistische und nichtprobabilistische Verfahren. Bei *probabilistischen* Klassifikatoren werden Wahrscheinlichkeitskonzepte zur Bestimmung der Entscheidungsfunktion herangezogen [Bishop, 2006]. Dabei werden sowohl die Merkmale \mathbf{x} als auch die Klassenlabels y als Zufallsvariable betrachtet. Die gemeinsame Verteilung der beiden Zufallsvariablen wird durch die Verbundwahrscheinlichkeitsdichte $p(\mathbf{x}, y)$ beschrieben. Bei der Klassifikation wird die a-posteriori Wahrscheinlichkeit $p(y_n|\mathbf{x}_n)$ für ein Klassenlabel $y_n \in \mathcal{Y}$ mit $\mathcal{Y} = \{C^1, \dots, C^\kappa, \dots, C^K\}$ bei gegebenem Merkmalsvektor \mathbf{x}_n für das n -te Pixel als Entscheidungsfunktion herangezogen, deren Parameter aus Trainingsdaten ermittelt werden können. Die Klassifikation erfolgt durch die *Maximierung der a-posteriori Wahrscheinlichkeit* (MAP-Prinzip) auf den Testdaten [Bishop, 2006]:

$$y_n = f(\mathbf{x}_n) = \arg \max_{C^\kappa \in \mathcal{Y}} p(y_n = C^\kappa | \mathbf{x}_n). \quad (2.1)$$

Bei *nichtprobabilistischen* Klassifikatoren dagegen basiert die Entscheidung über die Klassenzugehörigkeit, wie der Name bereits verrät, nicht auf Wahrscheinlichkeiten, sondern sie wird unmittelbar anhand eines Merkmalsvektors getroffen [Bishop, 2006]. Das Training basiert auf der Ermittlung einer optimalen Trennfläche zwischen den Klassenverteilungen im Merkmalsraum aus den Trainingsdaten. Trotz der nichtprobabilistischen Natur der Verfahren dieser Kategorie lässt sich deren Ergebnis meist probabilistisch interpretieren, wie z.B. beim *Random Forests* (RF) [Breiman, 2001]. Weitere bekannte Beispiele für nichtprobabilistische Klassifikatoren sind: *Support Vector Machines* (SVM) [Cortes und Vapnik, 1995] und *Convolutional Neural Networks* (CNN) [LeCun et al., 1989]. Es werden hier ausschließlich statistischen Methoden der Bildanalyse mit dem Schwerpunkt auf probabilistischen Ansätzen betrachtet, da nur diese für die vorliegende Arbeit relevant sind.

Generative und diskriminative Klassifikatoren. Der wesentliche Unterschied zwischen generativen und diskriminativen Klassifikatoren besteht beim Schätzen der Entscheidungsfunktion

$p(y|\mathbf{x})$ aus den Trainingsdaten. Bei generativen Ansätzen wird zunächst die gemeinsame Wahrscheinlichkeit $p(\mathbf{x}, y)$ modelliert, mit der anschließend die a-posteriori Wahrscheinlichkeit $p(y|\mathbf{x})$ mit Hilfe des Theorems von Bayes bestimmt wird. Ein Vorteil generativer Ansätze ist, dass synthetische Daten durch Sampling mit Hilfe der modellierten Wahrscheinlichkeitsverteilung $p(\mathbf{x}, y)$ erzeugt werden können. Allerdings erfordert die Modellierung selbst die Annahme über eine zugrundeliegende Verteilung, die in den realen Anwendungen nicht immer bekannt ist. Bei diskriminativen Ansätzen erfolgt dagegen eine direkte Modellierung der Entscheidungsfunktion $p(y|\mathbf{x})$ aus den Trainingsdaten \overline{TD} . Ein solches Modell lässt sich häufig durch weniger Parameter beschreiben als ein generatives Modell, weshalb diskriminative Klassifikatoren im Allgemeinen mit weniger Trainingsdaten auskommen als generative [Bishop, 2006]. Ein Beispiel für diskriminative probabilistische Klassifikatoren ist die Logistische Regression, die in Abschnitt 2.1.1 näher erläutert wird.

2.1.1 Logistische Regression

Überblick. Logistische Regression (LR) ist ein diskriminativer probabilistischer Klassifikator mit geringerer Rechenkomplexität, der unmittelbar auf Mehrklassenprobleme erweitert werden kann. Es sind außerdem keine Annahmen über die Verteilung der Daten zum Anlernen der LR notwendig. Die LR modelliert die a-posteriori Wahrscheinlichkeiten $p(y_n = C^\kappa | \mathbf{x}_n)$ der Klassenlabels $y_n = C^\kappa \in \mathcal{Y}$ bei gegebenen Daten \mathbf{x}_n (Merkmalsvektor) aus dem Merkmalsraum \mathcal{X} direkt. Zum Lernen der a-posteriori Wahrscheinlichkeiten steht ein Trainingsdatensatz \overline{TD} aus N gelabelten Trainingsbeispielen wie in Kapitel 2.1 bereits beschrieben zur Verfügung. Nachdem das Modell der a-posteriori Wahrscheinlichkeiten im Training geschätzt wurde, wird es als Entscheidungsfunktion f zur Klassifikation eingesetzt. Dabei nimmt der Klassifikator einen beliebigen Merkmalsvektor aus einer neuen zu klassifizierenden Szene als Argument und liefert gemäß Gleichung 2.1 jenes Klassenlabel als Ergebnis, für welches die a-posteriori Wahrscheinlichkeit maximal ist. In der Abbildung 2.1 sind einige Beispielergebnisse der LR in einem 2D Merkmalsraum für unterschiedliche Szenarien dargestellt.

Transformation der Merkmalsvektoren. Die LR basiert auf generalisierten linearen Modellen und liefert im Allgemeinen lineare Entscheidungsgrenzen für mehrdimensionale Merkmalsräume in Form von Hyperebenen, die jeweils die Merkmalsvektoren verschiedenen Klassen voneinander trennen. Um nichtlineare Entscheidungsgrenzen zu erhalten bzw. um nicht linear separierbare Klassen zu trennen, kann eine Transformation der Merkmalsvektoren (en: *feature space mapping*) durchgeführt werden. Dabei geht man in einen höherdimensionalen Raum $\Phi(\mathbf{x}_n) = [\Phi_1(\mathbf{x}_n), \dots, \Phi_M(\mathbf{x}_n)]^T$ über, in dem die Existenz einer Trennhyperebene zwischen den transformierten Merkmalsvektoren angenommen wird, wobei M die Dimension der transformierten Merkmalsvektoren ist. Das heißt, anstelle der ursprünglichen Merkmale \mathbf{x}_n wird die LR auf einen erweiterten Vektor $\Phi(\mathbf{x}_n)$ angewendet, dessen Komponenten Funktionen der Komponenten von \mathbf{x}_n sind. Ein Beispiel für eine Transformation der Merkmale ist die polynomiale Erweiterung, in der $\Phi(\mathbf{x}_n)$ alle möglichen Potenzen und Mischprodukte der Komponenten von \mathbf{x}_n mit einem Grad, der kleiner oder gleich dem Grad der Erweiterung ist, erhält.

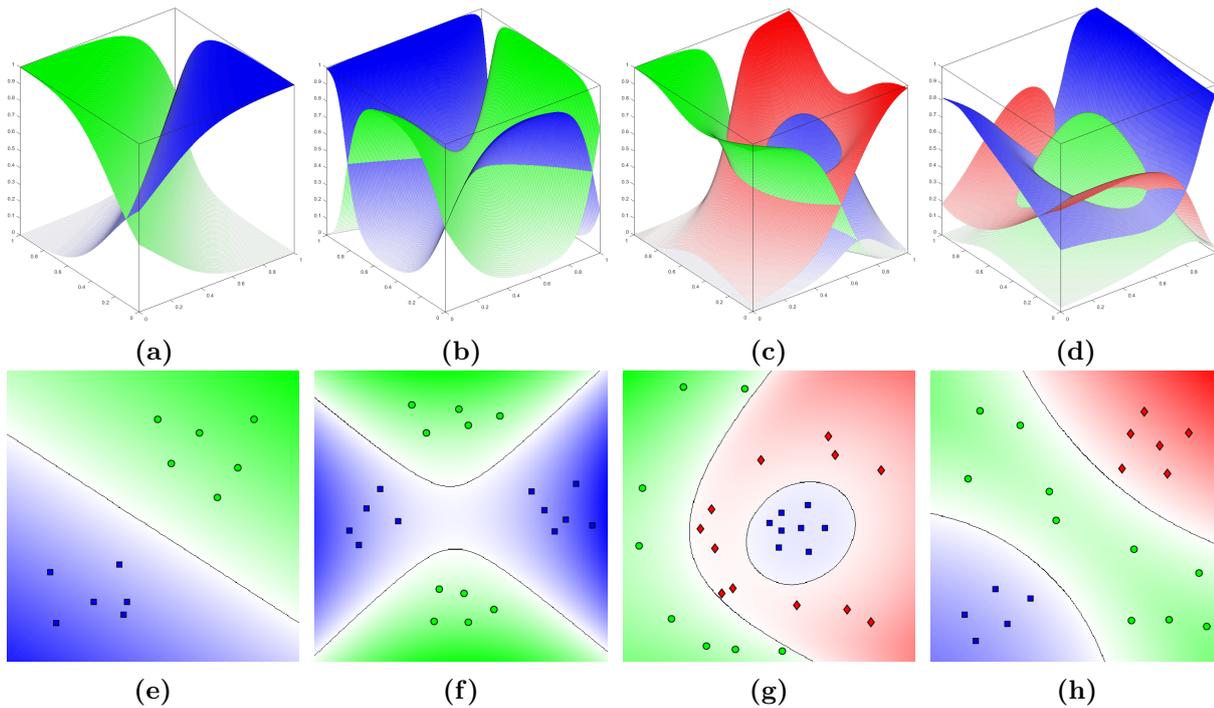


Abbildung 2.1: Beispielergebnisse der Logistischen Regression für acht unterschiedliche Szenarien im 2D-Merkmalraum. Bilder (a) - (d) zeigen die a-posteriori Wahrscheinlichkeiten der jeweiligen Klassen des angelerten Klassifikators (farbkodiert), während die Bilder (e) - (h) eine Aufteilung des Merkmalsraums auf Basis der maximalen Werte für die Wahrscheinlichkeit einer Klasse repräsentieren. Trainingsbeispiele aus der jeweiligen Klasse sind als geometrische Figuren dargestellt: Quadrate (blau), Kreise (grün) und Rauten (rot). Die schwarze Linie ist die Entscheidungsgrenze des angelerten Klassifikators. Je dunkler die Farbe, desto höher die Wahrscheinlichkeit für eine Klasse in der jeweiligen Region des Merkmalsraums.

Softmax Funktion als Modell der a-posteriori Wahrscheinlichkeiten. Die a-posteriori Wahrscheinlichkeit des LR-Klassifikators wird im Zweiklassenfall ($\mathcal{Y} = \{C^1, C^2\}$ mit $K = |\mathcal{Y}| = 2$) mit Hilfe der *logistischen Sigmoidfunktion* $\text{sig}(\cdot)$ modelliert [Bishop, 2006]:

$$p(C^1|\mathbf{x}_n) = \frac{1}{1 + \exp(-\mathbf{w}^T \cdot \Phi(\mathbf{x}_n))} = \text{sig}(\mathbf{w}^T \cdot \Phi(\mathbf{x}_n)), \quad (2.2)$$

mit $p(C^2|\mathbf{x}_n) = \text{sig}(-\mathbf{w}^T \cdot \Phi(\mathbf{x}_n))$. Dabei ist \mathbf{w} in Gleichung 2.2 ein Parametervektor, der im Training bestimmt wird. Dieser Parametervektor beschreibt die Hyperebene im transformierten Merkmalsraum $\Phi(\mathbf{x})$, die die Merkmalsvektoren einer Klasse von jenen der anderen Klasse trennt. Der Parametervektor \mathbf{w} beinhaltet dabei an erster Stelle ein konstantes Glied w_0 , das als Bias bezeichnet wird. Durch den Bias-Parameter des generalisierten linearen Modells wird eine Verschiebung der Hyperebene gegenüber dem Ursprung beschrieben. Das erste Element $\Phi_1(\mathbf{x}_n)$ des transformierten Merkmalsvektors wird als eine Konstante mit dem Wert 1 angenommen, um die Darstellung einfach zu halten.

Bei Mehrklassenproblemen ($\mathcal{Y} = \{C^1, \dots, C^k, \dots, C^K\}$ mit $K > 2$) wird die a-posteriori Wahr-

scheinlichkeiten auf Basis der Softmax-Funktion modelliert [Bishop, 2006]:

$$p(y_n = C^\kappa | \mathbf{x}_n) = \frac{\exp(\mathbf{w}_\kappa^T \cdot \Phi(\mathbf{x}_n))}{\sum_{j=1}^K \exp(\mathbf{w}_j^T \cdot \Phi(\mathbf{x}_n))}, \quad (2.3)$$

wobei der Term \mathbf{w}_κ den Parametervektor für eine bestimmte Klasse C^κ beschreibt. Es gibt für jede Klasse $C^\kappa \in \mathcal{Y}$ einen solchen Parametervektor \mathbf{w}_κ , der im Training zu bestimmen ist. Da die Summe der a-posteriori Wahrscheinlichkeiten über alle Klassen 1 sein muss, sind die Parametervektoren aus der Gleichung 2.3 nicht unabhängig. Dies kann berücksichtigt werden, indem der Parametervektor aus der Gleichung 2.3 um eine Klasse, z.B. von \mathbf{w}_1 , reduziert wird, ohne dabei die a-posteriori Wahrscheinlichkeit zu verändern [Roscher und Förstner, 2009; Zahid und Tutz, 2013]: $p(y_n = C^\kappa | \mathbf{x}_n) = (\exp(\mathbf{w}_\kappa - \mathbf{w}_1)^T \cdot \Phi(\mathbf{x}_n)) / (1 + \sum_{j=2}^K \exp((\mathbf{w}_j - \mathbf{w}_1)^T \cdot \Phi(\mathbf{x}_n)))$. Das ist äquivalent dazu, dass der Parametervektor \mathbf{w}_1 auf 0 gesetzt wird: $\mathbf{w}_1 = 0$. Damit enthält das Modell $(K - 1) \cdot M$ unabhängige Parameter. Diese im Training zu lernende Parameter \mathbf{w}_κ werden in einem gemeinsamen Parametervektor $\mathbf{w} = (\mathbf{w}_2^T, \dots, \mathbf{w}_K^T)^T$ zusammengefasst.

Maximum Likelihood Training. Beim ML Training basiert das Lernen des Parametervektors \mathbf{w} bei der LR auf der Maximierung der Likelihood-Funktion [Bishop, 2006]:

$$p(\overline{TD} | \mathbf{w}) = \prod_{n=1}^N \prod_{\kappa=1}^K p(y_n = C^\kappa | \mathbf{x}_n, \mathbf{w})^{t_{n\kappa}}. \quad (2.4)$$

In Gleichung 2.4 ist $p(y_n = C^\kappa | \mathbf{x}_n, \mathbf{w})$ die a-posteriori Wahrscheinlichkeit entsprechend der Gleichung 2.3. Die Variable $t_{n\kappa}$ ist eine Indikatorvariable, die den Wert 1 annimmt, wenn das Klassenlabel y_n des Trainingsbeispiels n aus dem \overline{TD} den Wert C^κ aufweist und sonst Null ist.

Die Formel aus Gleichung 2.4 kann durch Bildung des negativen Logarithmus der Likelihood-Funktion wie folgt umgeformt werden, wodurch aus dem Produkt eine leichter zu handhabende Summe wird:

$$E(\mathbf{w}) = -\ln(p(\overline{TD} | \mathbf{w})) = -\sum_{n=1}^N \sum_{\kappa=1}^K t_{n\kappa} \cdot \ln(y_{n\kappa}), \quad (2.5)$$

wobei die Kurzform $y_{n\kappa}$ für die a-posteriori Wahrscheinlichkeit $y_{n\kappa} = p(y_n = C^\kappa | \mathbf{x}_n, \mathbf{w})$ aus Gleichung 2.3 steht. Diese Zielfunktion ist einfacher zu handhaben und aufgrund der Summenbildung numerisch stabiler gegenüber Gleichung 2.4. Der Logarithmus ist eine streng monoton steigende Funktion. Damit kann anstelle der Maximierung der Likelihood $p(\overline{TD} | \mathbf{w})$ die Minimierung der negativen Log-Likelihood-Funktion erfolgen, d.h. das zugehörige Optimierungsproblem beim ML Training der LR lautet:

$$\min_{\mathbf{w} \in \mathbb{R}^M} \{E(\mathbf{w})\} = \min_{\mathbf{w} \in \mathbb{R}^M} \left\{ -\sum_{n=1}^N \sum_{\kappa=1}^K t_{n\kappa} \cdot \ln(y_{n\kappa}) \right\}. \quad (2.6)$$

Regularisierung. Ein Nachteil beim ML Training ist, dass keine a-priori Wahrscheinlichkeit für den Parametervektor \mathbf{w} des Modells berücksichtigt wird. Das ML Training orientiert sich allein an

den Trainingsbeispielen in \overline{TD} . Dadurch wird die Modellkomplexität nicht eingeschränkt und es kann schnell zu einer Überanpassung kommen [Süße und Rodner, 2014]. Bei der Überanpassung wird das trainierte Modell so gut an die Trainingsdaten (inklusive Ausreißer) angepasst, dass es für zukünftige Testdaten unter Umständen nicht mehr optimale Ergebnisse liefert. Um der Überanpassung entgegenzuwirken soll daher eine hohe Modellkomplexität vermieden werden. In der Praxis wird ein zusätzlicher Regularisierungsterm in die Kostenfunktion eingefügt, der komplexe Modelle mit großer Varianz der Parameter bestraft.

Beim Training mit Regularisierung basiert das Lernen des Parametervektors \mathbf{w} genähert auf der Maximierung der a-posteriori Wahrscheinlichkeit für die Parameter \mathbf{w} [Vishwanathan et al., 2006]:

$$p(\mathbf{w}|\overline{TD}) \propto p(\mathbf{w}) \cdot \prod_{n=1}^N \prod_{\kappa=1}^K p(y_n = C^\kappa | \mathbf{x}_n, \mathbf{w})^{t_{n\kappa}}, \quad (2.7)$$

wobei der Faktor $p(\mathbf{w})$ ein a-priori Wissen über die Verteilung der Modellparameter beschreibt.

Die a-priori Wahrscheinlichkeit $p(\mathbf{w})$ wird häufig als Normalverteilung mit Erwartungswert 0 und Standardabweichung σ modelliert. Dies entspricht einer L2-Regularisierung, um Überanpassung zu vermeiden. Dabei steuert der Parameter σ die Stärke der Bestrafung von komplexen Modelle mit hohen Parameterwerten in \mathbf{w} . Falls σ klein gewählt wird, werden solche komplexen Modelle stärker bestraft und umgekehrt. Durch Bildung des negativen Logarithmus der a-posteriori Wahrscheinlichkeit und Vernachlässigung konstanter Terme ergibt sich für die Kostenfunktion $E(\mathbf{w})$ mit Regularisierungsterm folgende Gleichung:

$$E(\mathbf{w}) = -\ln(p(\mathbf{w}|\overline{TD})) = -\sum_{n=1}^N \sum_{\kappa=1}^K t_{n\kappa} \cdot \ln(y_{n\kappa}) + \frac{\mathbf{w}^T \cdot \mathbf{w}}{2 \cdot \sigma^2}. \quad (2.8)$$

Das zugehörige Optimierungsproblem ergibt sich damit analog zu Gleichung 2.6.

Optimierung mittels des Newton-Raphson-Verfahrens. Die Kostenfunktion aus der Gleichung 2.5 bzw. 2.8 ist konkav [Bishop, 2006] und besitzt somit ein einziges Minimum. Das Verfahren nach Newton-Raphson ist eine effiziente iterative Technik zur Suche nach dem Minimum von solchen nichtlinearen Funktionen. Ausgehend von einem Initialwert \mathbf{w}_0 findet die Aktualisierung des Parametervektors \mathbf{w}^τ in der aktuellen Iteration τ nach dem folgenden Schema statt [Bishop, 2006]:

$$\mathbf{w}^\tau = \mathbf{w}^{\tau-1} + \mathbf{H}^{-1} \nabla E(\mathbf{w}^{\tau-1}). \quad (2.9)$$

Die Terme $\nabla E(\mathbf{w})$ und \mathbf{H} in der Gleichung 2.9 sind der Gradient bzw. die Hesse Matrix der Kostenfunktion $E(\mathbf{w})$ aus der vorherigen Iteration $\tau - 1$.

Der Gradient $\nabla E(\mathbf{w})$ besteht aus partiellen Ableitungen von $E(\mathbf{w})$ aus Gleichung 2.6 nach dem jeweiligen Parametervektor \mathbf{w}_κ der Klasse C^κ , wobei $\kappa \in [2, \dots, K]$, d.h. $\nabla E(\mathbf{w}) = [\nabla_{\mathbf{w}_2} E(\mathbf{w})^T, \dots, \nabla_{\mathbf{w}_K} E(\mathbf{w})^T]^T$, mit:

$$\nabla_{\mathbf{w}_\kappa} E(\mathbf{w}) = \sum_{n=1}^N (y_{n\kappa} - t_{n\kappa}) \cdot \Phi(\mathbf{x}_n) + \frac{1}{\sigma^2} \cdot \mathbf{w}_\kappa. \quad (2.10)$$

Die Hesse Matrix \mathbf{H} besteht aus $(K-1) \times (K-1)$ Blöcken $\mathbf{H}_{j\kappa}$ der Größe $M \times M$, wobei jeder Block aus zweiten partiellen Ableitungen von $E(\mathbf{w})$ nach \mathbf{w}_κ und \mathbf{w}_j gebildet wird, die wie folgt definiert sind:

$$\mathbf{H}_{j\kappa} = \nabla_{\mathbf{w}_j} \nabla_{\mathbf{w}_\kappa} E(\mathbf{w}) = - \sum_{n=1}^N (y_{nj} \cdot (I_{j\kappa} - y_{n\kappa}) \cdot \Phi(\mathbf{x}_n) \cdot \Phi(\mathbf{x}_n)^T) + \frac{\mathbb{1}[j = \kappa]}{\sigma^2} \cdot \mathbf{I}, \quad (2.11)$$

wobei \mathbf{I} die Einheitsmatrix ist, die aus einzelnen Elementen $I_{j\kappa}$ besteht. Die Funktion $\mathbb{1}[\cdot]$ ist die Indikatorfunktion, die den Wert 1 liefert, sobald ihr Argument wahr ist, und sonst den Wert 0 hat. Das bedeutet, dass der letzte Term nur für die Blöcke an der Hauptdiagonale der Hesse Matrix ungleich Null ist. Das iterative Schema nach Newton-Raphson aus der Gleichung 2.9 wird solange wiederholt, bis die Norm des Gradienten $\nabla E(\mathbf{w})$ numerisch gleich Null ist.

2.2 Transferlernen

Bei traditionellen überwachten Methoden des maschinellen Lernens wird versucht, die Zusammenhänge zwischen Merkmalsvektoren als Eingangsdaten und Klassenlabels als Ausgangsdaten für zukünftige Aufgaben aus zuvor gesammelten Daten zu erlernen [Yin et al., 2006; Baralis et al., 2008; Voisin et al., 2014]. Dabei gehen diese Methoden von der Annahme aus, dass die Elemente der Trainingsdaten aus der selben Verteilung wie Testdaten gezogen wurden und somit die gleichen statistischen Eigenschaften aufweisen (Kap. 2.1). Ein Problem im Zusammenhang mit dem maschinellen Lernen in diesem Kontext ist die Notwendigkeit, eine ausreichend große Menge an repräsentativen Trainingsdaten für jede neue Aufgabe bereitzustellen. Während die Verwendung von Trainingsdaten diesen Klassifikationsmethoden ermöglicht, sich an die spezifischen Merkmalsverteilungen in unterschiedlichen Szenen anzupassen, ist deren Erfassung, insbesondere die Generierung der Klassenlabels, eine teure und langwierige, oft manuelle Aufgabe. Die Anwendung eines angelernten Klassifikators auf ein anderes Bild als jenes, aus dem die Trainingsdaten generiert wurden, würde den manuellen Arbeitsaufwand reduzieren. Diese Strategie führt jedoch zu suboptimalen Ergebnissen, falls die Daten im neuen Bild einer anderen Verteilung als im Trainingsbild folgen. Speziell in den Anwendungen aus der Fernerkundung ist die Annahme über gleiche statistische Eigenschaften aufgrund von unterschiedlichen Sensorcharakteristiken, Beleuchtungsverhältnissen, saisonalen Effekten, aber auch z.B. aufgrund unterschiedlicher Bebauungsdichte in den urbanen Gebieten, relativen Klassenhäufigkeiten usw. schwer zu halten. Verfahren des Transferlernens (TL) können hier Abhilfe schaffen.

2.2.1 Definitionen und Notation

Diese Arbeit orientiert sich in Bezug auf die Notation und Einordnung der unterschiedlichen Transferlernen-Methoden an [Tuia et al., 2016]. In der Terminologie des TL wird zwischen *Domänen* (en: *domains*) und *Aufgaben* (en: *tasks*) unterschieden. Eine Domäne $\mathcal{D} = \{\mathcal{X}, p(\mathbf{x})\}$

besteht aus einem Merkmalsraum \mathcal{X} und einer Wahrscheinlichkeitsverteilung $p(\mathbf{x})$ der Merkmalsvektoren. In jeder Domäne ist eine Lernaufgabe \mathcal{T} zu lösen. Die Lernaufgabe $\mathcal{T} = \{\mathcal{Y}, f(\cdot)\}$ besteht aus einer Menge der Klassen \mathcal{Y} und einer Entscheidungsfunktion $f(\cdot)$ zur Prädiktion der Labels bzw. Klassen aus \mathcal{Y} bei gegebenen Merkmalsvektoren \mathbf{x} . Die Entscheidungsfunktion kann an den Trainingsbeispielen (\mathbf{x}_n, y_n) mit $\mathbf{x}_n \in \mathcal{X}$ und $y_n \in \mathcal{Y}$ angelernt werden. Beim TL bezeichnet man einen vorhandenen Datensatz als Quelle S (en: *source*), von der Wissen auf einen neuen Datensatz, den Zieldatensatz T (en: *target*), übertragen wird. Sowohl Quell- als auch Zieldatensatz sind durch ihre Domänen und Lernaufgaben vollständig beschrieben, wobei diese sich voneinander unterscheiden können. Damit ein Transfer möglich ist, dürfen die Unterschiede zwischen den Domänen bzw. Lernaufgaben jedoch nicht zu stark ausfallen [Pan und Yang, 2010]; diese Voraussetzung wird als *Ähnlichkeitsbedingung* bezeichnet. Zusammengefasst besteht das Ziel des TL darin, für die gegebene Domänen \mathcal{D}_S und \mathcal{D}_T mit dazugehörigen Lernaufgaben \mathcal{T}_S und \mathcal{T}_T das Lernen der Zielfunktion $f_T(\cdot)$ in \mathcal{D}_T mit Hilfe des Wissens aus \mathcal{D}_S oder/und \mathcal{T}_S zu verbessern.

2.2.2 Domänenadaption

Der Fokus in dieser Arbeit liegt auf der Domänenadaption (en: *domain adaptation: DA*). Nach der ursprünglichen Definition von Pan und Yang [2010] liegt die DA vor, wenn die Quell- und Zielaufgabe identisch ($\mathcal{T}_S = \mathcal{T}_T$) und die Domänen unterschiedlich ($\mathcal{D}_S \neq \mathcal{D}_T$) sind, wobei der Unterschied zwischen den Domänen allein in der Randverteilungen der Merkmalsvektoren $p(\mathbf{x}_S) \neq p(\mathbf{x}_T)$ liegt und die Merkmalsräume identisch ($\mathcal{X}_S = \mathcal{X}_T$) sind. Aufgrund der Ähnlichkeitsbedingung dürfen die Unterschiede zwischen den Domänen auch hier nicht zu groß sein, um Wissenstransfer zu ermöglichen. Die Annahme über identische Quell- und Zielaufgabe impliziert, dass sowohl die Menge der Klassenlabels als auch die a-posteriori Wahrscheinlichkeiten der Klassen zwischen den beiden Domänen geteilt werden, d.h. $\mathcal{Y}_S = \mathcal{Y}_T$ und $p(y_S|\mathbf{x}_S) = p(y_T|\mathbf{x}_T)$. Die zweite Annahme ist jedoch stark und kann nicht immer in realen Anwendungen eingehalten werden. Daher wird die Definition der DA meist so gelockert, dass nur die Annahme über die gleichen Klassenlabels $\mathcal{Y}_S = \mathcal{Y}_T$ und Merkmalsräume $\mathcal{X}_S = \mathcal{X}_T$ erforderlich ist [Bruzzone und Marconcini, 2010; Csurka, 2017].

Kategorisierung der Ansätze nach Verfügbarkeit von Trainingsdaten. Die DA-Ansätze können nach der Verfügbarkeit von Trainingsdaten in der Quell- und Zieldomäne in folgende drei Kategorien unterteilt werden [Tuia et al., 2016]:

- *Überwachte DA* (en: *supervised*): Methoden in dieser Gruppe setzen voraus, dass gelabelte Daten für Quell- und Zieldomäne zur Verfügung stehen.
- *Semi-überwachte DA* (en: *semi-supervised*): Diese Gruppe von Methoden geht davon aus, dass gelabelte Daten nur in der Quelldomäne vorliegen.
- *Unüberwachte DA* (en: *unsupervised*): Die unüberwachten DA-Methoden nehmen an, dass gar keine gelabelte Daten vorhanden sind.

In dieser Arbeit wird für die DA entsprechend [Bruzzone und Marconcini, 2010; Csurka, 2017] neben der identischen Merkmalsräume ($\mathcal{X}_S = \mathcal{X}_T$) nur die Menge der Klassenlabels in den beiden Domänen als gleich angenommen ($\mathcal{Y}_S = \mathcal{Y}_T$). Die Quell- und Zieldomäne unterscheiden sich in der gemeinsamen Verteilung der Stichproben \mathbf{x} und deren Klassenlabels y , d.h. $p(\mathbf{x}_S, y_S) \neq p(\mathbf{x}_T, y_T)$, wobei $p(\mathbf{x}, y) = p(y|\mathbf{x}) \cdot p(\mathbf{x})$ ist. Somit können die Unterschiede zwischen den Domänen aus der Randverteilung der Daten $p(\mathbf{x}_S) \neq p(\mathbf{x}_T)$ und/oder aus der bedingten Verteilung der Klassen bei gegebenen Daten $p(y_S|\mathbf{x}_S) \neq p(y_T|\mathbf{x}_T)$ resultieren (siehe Abbildung 2.2). Außerdem wird in dieser Arbeit ein semi-überwachter Ansatz zur DA verfolgt. Daher muss der zu schätzende Zusammenhang zwischen den Merkmalsvektoren und den Objektklassen im Kontext des Wissenstransfers bei der DA zunächst an den Trainingsbeispielen aus der Quelldomäne angelernt werden und anschließend auf die Zieldomäne übertragen werden.

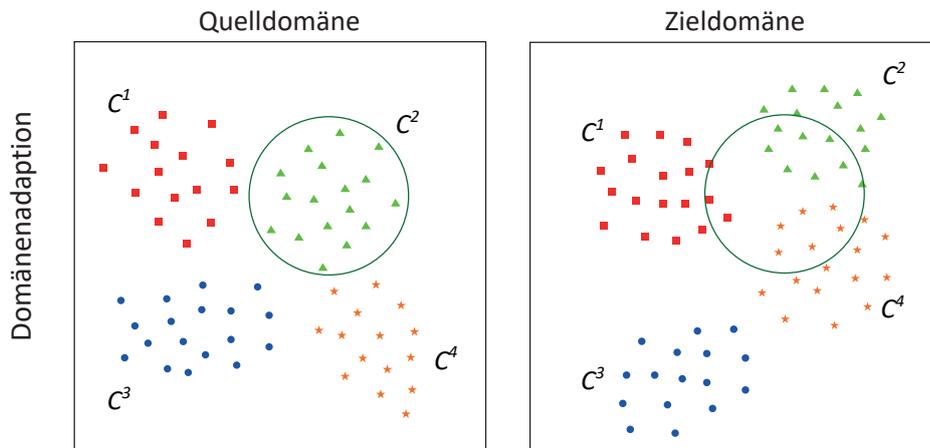


Abbildung 2.2: Exemplarisches Beispiel für ein Domänenadaptionsproblem. Das Bild stellt gelabelte Stichproben aus der Quell- und Zieldomäne für eine Klassifikationsaufgabe mit 4 Klassen in einem 2D-Merkmalsraum dar. Die Verteilungen der Stichproben unterscheiden sich zwischen der Quell- und Zieldomäne, wobei der Kreis die Position der Stichproben der Klasse C^2 (grüne Dreiecke) in der Quelldomäne markiert (Eigene Darstellung in Anlehnung an [Tuia et al., 2016]).

Kategorisierung der Ansätze nach Art des zu transferierenden Wissens. Die Methoden der DA können weiter nach Art des tatsächlich zu transferierenden Wissens unterteilt werden. Nahezu alle Methoden der DA lassen sich in folgende zwei Kategorien unterteilen [Pan und Yang, 2010]:

- *Transfer der Merkmalsrepräsentation* (en: *feature representation transfer*): Verfahren in dieser Kategorie versuchen, die Unterschiede zwischen den Verteilungen der Daten aus der Quell- und Zieldomäne durch Projizieren beider Domänen in einen gemeinsamen Merkmalsraum zu reduzieren [Bruzzone und Persello, 2009; Gopalan et al., 2011; Tuia et al., 2014]. Dabei wird meistens folgendermaßen vorgegangen: eine Menge an invarianten Merkmalen wird aus den vorhandenen Merkmalen gelernt, oder es findet eine geeignete Merkmalstransformation in einen latenten Raum mit dem Ziel statt, die Verteilungen der Daten aus beiden Domänen in diesem Raum einander anzugleichen.
- *Transfer von Instanzen* (en: *instance transfer*): Bei diesen Verfahren werden Instanzen (Trainingsbeispiele) aus der Quelldomäne zum Training des Klassifikators in der Ziel-

domäne verwendet [Dai et al., 2007; Bruzzone und Marconcini, 2010; Bahirat et al., 2012]. Der Klassifikator wird dabei sukzessive an die Verteilung der Daten von der Zieldomäne angepasst, während den Stichproben aus der Zieldomäne Pseudo-Labels (auch Semi-Labels genannt) vergeben werden, welche aus dem aktuellen Zustand des Klassifikators resultieren. Verfahren zum Transfer von Instanzen sind insofern interessant, als sie den herkömmlichen überwachten Klassifikationsmethoden sehr nahe stehen und daher intuitiver sind. Aus diesem Grund werden in der vorliegenden Arbeit Methoden des Transfers von Instanzen zur Anpassung des Klassifikators an die Zieldomäne eingesetzt.

Für einen umfassenden Überblick über die unterschiedlichen Einstellungen und Ansätze in TL und DA wird an dieser Stelle zusätzlich auf die Literatur verwiesen [Pan und Yang, 2010; Tuia et al., 2016; Csurka, 2017; Wang und Deng, 2018].

2.2.3 Negativer Transfer

Im Unterschied zu traditionellen überwachten Methoden können sowohl Rand- als auch bedingte Klassenverteilungen der Merkmalsvektoren aus der Quell- und der Zieldomäne beim TL sich unterscheiden. Um einen Wissenstransfer trotzdem zu ermöglichen, werden die Annahmen über gewisse Ähnlichkeiten der Domänen und/oder der Lernaufgaben getroffen. Eaton et al. [2008] zeigen z.B., dass die Leistungsfähigkeit des Transferlernens davon abhängig ist, wie stark die Quell- und Zieldomänen zusammenhängen. Werden die Annahmen über die Ähnlichkeit verletzt, ist der Ausgang des Wissenstransfers ungewiss. Es muss dann mit einem *negativen Transfer* (NT) gerechnet werden. Darunter versteht man eine Verringerung der Klassifikationsgenauigkeit nach dem Transfer im Vergleich zu direkter Anwendung des anhand von Daten aus einer oder mehreren Quellen angelernten Klassifikators auf die Daten der Zieldomäne.

Es ist jedoch schwierig, ein aussagekräftiges Maß für die Ähnlichkeit zwischen der Quell- und Zieldomäne zu finden, daher werden die Annahmen über Ähnlichkeit der Domänen in den meisten Arbeiten nicht explizit erfasst. Für den Fall, in dem gelabelte Trainingsdaten in beiden Domänen verfügbar sind, wie z.B. beim induktiven TL oder bei der überwachten DA, lässt sich die Erkennung vom NT durch einen einfachen Abgleich der beim Transfer ermittelten Klassenlabels mit den vorhandenen Referenzlabels relativ unproblematisch gestalten. Bei der DA besteht das Problem der Erkennung bzw. Vermeidung von NT allerdings nach wie vor, wenn nur wenige oder gar keine gelabelte Daten in der Zieldomäne verfügbar sind. Die meisten aktuellen Ansätze zur Vermeidung oder Erkennung vom NT (siehe Kapitel 3.1.6) basieren entweder auf der Annahme der Symmetrie bei der Wissensübertragung von $S \rightarrow T$ und $T \rightarrow S$ (wie z.B. bei der *circular validation strategy* von Bruzzone und Marconcini [2010]) oder auf einem Distanzmaß zur Bestimmung der Ähnlichkeit von Domänen (wie z.B. in [Vogt et al., 2018]). Während die Annahme über Symmetrie der Wissensübertragung in realen Anwendungen nicht immer eingehalten werden kann [Eaton et al., 2008], stellt die Messung der Ähnlichkeit zwischen den Domänen auf Basis der Verteilungen der Merkmalsvektoren eine flexible Alternative dazu dar. Eine effiziente Technik zur Messung der Ähnlichkeit zwischen zwei Verteilungen wird im nächsten Abschnitt vorgestellt.

2.3 Maximum Mean Discrepancy

Die Maximum Mean Discrepancy (MMD) von [Gretton et al., 2012] liefert ein generisches Maß für die Ähnlichkeit zweier Verteilungen als Abstand zwischen den Mittelwerten von deren Wahrscheinlichkeitsverteilungen in einem Hilbertraum mit reproduzierendem Kern (en: *Reproducing Kernel Hilbert Space*: RKHS). Sie kann daher als Distanzmetrik für die Ähnlichkeit der Quell- und Zieldomäne, genauer gesagt der Randverteilungen der Merkmalsvektoren, eingesetzt werden. Dabei sind keine Kenntnisse über Klassenlabels erforderlich, was sich für den Fall einer semi-überwachten DA als günstig erweist.

In der Praxis wird MMD empirisch unter Verwendung eines Teils der Daten (Merkmalsvektoren) aus den zu untersuchenden Verteilungen berechnet. Es sind nach Gretton et al. [2012] jeweils zwei unabhängige Stichprobenmengen von Merkmalsvektoren aus der jeweiligen zu untersuchenden Verteilung zur Schätzung der MMD erforderlich. Die Domänendistanz $d_{MMD}(S, T)$ auf Basis der MMD-Metrik kann anschließend durch den unverzerrten Schätzer mit minimaler Varianz wie folgt bestimmt werden [Gretton et al., 2012]:

$$d_{MMD}^2(S, T) = \frac{1}{\tilde{N}^2} \sum_{j=1}^{\tilde{N}} \sum_{l=1}^{\tilde{N}} k(\mathbf{x}_{S,j}, \mathbf{x}'_{S,l}) + \frac{1}{\tilde{N}^2} \sum_{j=1}^{\tilde{N}} \sum_{l=1}^{\tilde{N}} k(\mathbf{x}_{T,j}, \mathbf{x}'_{T,l}) - \frac{2}{\tilde{N}^2} \sum_{j=1}^{\tilde{N}} \sum_{l=1}^{\tilde{N}} k(\mathbf{x}_{S,j}, \mathbf{x}_{T,l}). \quad (2.12)$$

Die Variablen \mathbf{x} und \mathbf{x}' beschreiben die Merkmalsvektoren der zwei unabhängigen Stichprobenmengen aus derselben Verteilung: entweder aus der Quell- oder der Zieldomäne. Dabei ist der Umfang der Stichproben überall gleich groß und beträgt jeweils \tilde{N} Merkmalsvektoren. Der Term $k(\cdot)$ beschreibt dabei eine Kernelfunktion, die eine Merkmalstransformation vom ursprünglichen Merkmalsraum in den RKHS induziert. Dadurch muss die Transformation in diesen neuen Merkmalsraum nicht explizit berechnet werden. Dabei ist die Radiale Basisfunktion (kurz: RBF), auch Gaußkern genannt, von besonderer Bedeutung:

$$k_{\text{RBF}}(\mathbf{x}_j, \mathbf{x}_l) = \exp\left(-\frac{\|\mathbf{x}_j - \mathbf{x}_l\|^2}{2\sigma_{\text{MMD}}^2}\right). \quad (2.13)$$

Die RBF erlaubt durch eine geeignete Wahl von σ_{MMD} beliebig komplexe Merkmalsräume zu indizieren und somit eine Vielzahl der Ähnlichkeitsbeziehungen zwischen den zu untersuchenden Verteilungen in RKHS zu modellieren. Die Wahl einer geeigneten Kernelbandbreite bleibt jedoch weiterhin keine triviale Aufgabe. Sriperumbudur et al. [2009] zeigen, dass dafür am besten jener Wert der Kernelbandbreite σ_{MMD} geeignet ist, für den die MMD maximal wird.

Eine effiziente Lösung zur Bestimmung der Bandbreite wurde in [Vogt et al., 2018] vorgeschlagen. Die Bestimmung erfolgt auf Basis einer Schätzung der Bandbreite durch Adaption der Methode des *Goldenen Schnittes* (en: *Golden Section Search*) [Kiefer, 1953] für einen nicht unimoda-

len¹ Verlauf der MMD-Funktion gemäß dem Algorithmus in Tabelle 2.1 aus [Vogt et al., 2018]. Zu Beginn der Bestimmung der Bandbreite σ_{MMD} stehen am Eingang jeweils zwei unabhängige Stichproben aus den Daten der Quell- und Zieldomäne $\mathbf{x}_S, \mathbf{x}'_S, \mathbf{x}_T$ und \mathbf{x}'_T zur Verfügung, für die die MMD maximiert werden soll. Die Schätzung der Bandbreite erfolgt dabei in mehreren Iterationsschritten, während derer die Schätzung verfeinert wird. Die Idee zur Schätzung der Bandbreite basiert auf einer Intervallunterteilung und Auswertung der MMD-Funktion nur an bestimmten Stützstellen, wobei die allgemeine Form der Funktion als bekannt angenommen wird. Das Suchintervall (L, R) für Maximum der MMD-Funktion wird im Verlauf der Schätzung schrittweise verkleinert, wodurch der Schätzwert von σ_{MMD} verbessert wird. Das Startintervall $(0, \infty)$ wird dabei durch Verwendung der *atan*-Funktion auf das Intervall $(L, R) = (0, \frac{\pi}{2})$ abgebildet (vgl. mit Algorithmus aus Tabelle 2.1). Die Stützstellen, an denen die MMD-Funktion ausgewertet wird, sind die Stellen A und B . Die Wahl dieser Stellen hat dabei einen Einfluss auf die Qualität der resultierenden Schätzung der Bandbreite. Die Methode des Goldenen Schnittes aus [Kiefer, 1953] nutzt zur Bestimmung der optimalen Stützstellen die Zahl $\varphi \approx 1.618$, die es erlaubt, bereits nach wenigen Iterationen einen relativ kleinen Suchintervall und somit eine hohe Schätzungsgenauigkeit zu erreichen. Die Anzahl der Schritte ist hier durch die Variable *MaxIter* festgelegt und auf 10 Iterationen begrenzt.

Da die Bestimmung von d_{MMD} auf Basis der zufällig ausgewählten Stichprobenmengen einer gewissen Variabilität der Ergebnisse unterliegt, kommt weiterhin die *Bootstrap Aggregating* (BAGGING) Methode [Breiman, 1996] zum Einsatz, um die Robustheit der Berechnung zu verbessern. Dabei wird die Schätzung der MMD mehrmals unter Verwendung unterschiedlicher Stichproben (Bootstrap Datensätze), die unabhängig und zufällig aus der jeweiligen Verteilung gezogen wurden, wiederholt. Die resultierende Distanz wird als Mittelwert aus mehreren unabhängigen Schätzungen berechnet.

Der berechnete MMD-Wert wird in dieser Arbeit als ein Maß für den Abstand zwischen Quell- und Zieldomäne verwendet. Ein Schwellwert kann auf dieses Maß angewendet werden, um mögliche Fälle vom NT vorherzusagen.

¹Eine stetige Funktion, deren einziges Extremum schon globales Extremum ist, wird als unimodal bezeichnet. Eine unimodale Funktion ist somit entweder streng monoton steigend oder fallend bis zur Extremstelle und ändert nach dieser Stelle ihr Monotonieverhalten nur einmal im Verlauf der Funktion.

Tabelle 2.1: Schätzung der Bandbreite σ_{MMD} mit der Methode von Vogt et al. [2018].

Algorithmus: Schätzung der Bandbreite σ_{MMD}

Eingabe: $\mathbf{x}_S, \mathbf{x}'_S, \mathbf{x}_T, \mathbf{x}'_T, \text{MaxIter}$ *Ausgabe:* σ_{MMD} $\varphi := 1.61803398875$ $L := 0$ $R := \frac{\pi}{2}$ **for** $i = 1 : \text{MaxIter}$ **do** $A = R - \frac{R-L}{\varphi}$ $B = L + \frac{R-L}{\varphi}$ $\mathbf{f}_A = d_{\text{MMD}}^2(S, T)$ für $\sigma_A = \tan(A)$ $\mathbf{f}_B = d_{\text{MMD}}^2(S, T)$ für $\sigma_B = \tan(B)$ **if** $\mathbf{f}_A < 0$ **then** $R = A$ **else if** $\mathbf{f}_B \leq \mathbf{f}_A$ **then** $R = B$ **else** $L = A$ **end if****end for****return** $\sigma_{\text{MMD}} = \tan\left(\frac{L+R}{2}\right)$

3 Stand der Forschung

In diesem Kapitel wird ein für diese Arbeit relevanter methodischer Überblick über den Stand der Forschung präsentiert. Das Kapitel 3.1 beschäftigt sich mit den Methoden und verschiedenen Ansätzen zur Lösung der DA-Problemstellungen. In Abschnitt 3.2 werden die Grenzen der existierenden Methoden diskutiert und die Forschungslücke identifiziert, welche diese Arbeit schließen soll.

3.1 Domänenadaption

In der wissenschaftlichen Literatur über maschinelles Lernen finden sich zahlreiche Ansätze, die sich mit der TL- und DA-Problematik auseinandersetzen. Ein Fokus im Bereich der Fernerkundung richtet sich auf die Klassifikation von Luft- und Satellitenbildern. Grundsätzlich unterscheiden sich diese Ansätze hinsichtlich der Verfügbarkeit von Trainingsdaten in der Quell- und/oder Zieldomäne, der allgemeinen Vorgehensweise (was, wie bzw. wann zu transferieren ist), der Klassifikationsmethode und der Art von verwendeten Eingangsdaten. Im Folgenden wird auf existierende Arbeiten im Bereich der DA eingegangen. Bei der Betrachtung der einzelnen Ansätze und der Einordnung von Methoden orientiert sich die Übersicht in diesem Kapitel an [Tuia et al., 2016], wobei der Schwerpunkt auf Anwendungen in der Fernerkundung liegt. Eine umfassende Übersicht bieten weiterhin die wissenschaftlichen Veröffentlichungen zu diesem Thema [Pan und Yang, 2010; Patel et al., 2015; Tuia et al., 2016; Csurka, 2017; Wang und Deng, 2018].

In diesem Abschnitt werden die Voraussetzungen für diese Arbeit kurz zusammengestellt, um einen besseren Vergleich mit den alternativen Methoden zu ermöglichen. Im Rahmen dieser Arbeit soll ein DA-Ansatz zur Klassifikation von Luftbildern entwickelt werden. Außerdem soll eine Strategie zur Prädiktion von NT erarbeitet werden. Nach dem initialen Anlernen der Parameter soll die Adaption sowie die Erkennung von NT automatisch ohne Interaktion mit dem Benutzer verlaufen. Es steht dabei jeweils eine Quell- und eine Zieldomäne für die Adaption zur Verfügung, welche Daten von je einer Szene beinhalten. Die Labels liegen ausschließlich für die Szene aus der Quelldomäne vor. Die Quell- und Zieldomäne unterscheiden sich durch die gemeinsame Verteilung der Merkmalsvektoren \mathbf{x} und deren Klassenlabels y , d.h. $p(\mathbf{x}_S, y_S) \neq p(\mathbf{x}_T, y_T)$. Das ist äquivalent dazu, dass die Unterschiede sich aus der Randverteilung der Daten $p(\mathbf{x}_S) \neq p(\mathbf{x}_T)$ und/oder aus der bedingten Verteilung der Klassen bei gegebenen Daten $p(y_S|\mathbf{x}_S) \neq p(y_T|\mathbf{x}_T)$ ergeben können.

Der Rest des Kapitels ist folgendermaßen gegliedert. Zunächst werden kurz der DA verwandte Problemstellungen betrachtet. Dann werden die einzelnen Gruppen von Ansätzen zur DA in Hinblick auf die Verfügbarkeit von gelabelten Daten etwas genauer betrachtet. Da hier keine Labels in der Zieldomäne zur Verfügung stehen, liegt der Fokus bei den semi-überwachten Methoden zur DA. Weiterhin wird ein kurzer Überblick über die Methoden auf Basis von Deep Learning und neuronalen Netzen in der DA gegeben, die in den letzten Jahren eine erhöhte Aufmerksamkeit in vielen Bereichen des maschinellen Lernens genießen. Zum Schluss wird auf den Umgang mit NT in der aktuellen Literatur eingegangen.

3.1.1 Verwandte Problemstellungen

Strategien, die unter anderem das Problem der Reduktion der Anzahl von Trainingsdaten angehen, sind Methoden des *Aktives Lernens* (en: *Active Learning*) [Settles, 2012] und der *Klassifikation mit fehlerbehafteten Labels* (Label Noise) [Frenay und Verleysen, 2014]. Die Methoden des Aktives Lernens [Tuia et al., 2011b] treffen eine wohlüberlegte Auswahl der informativsten Stichproben aus einer ungelabelten Zieldomäne, die manuell von einem Benutzer zur Lösung der Klassifikationsaufgabe in der Zieldomäne gelabelt werden müssen. Der Ansatz in dieser Arbeit kommt im Gegensatz dazu ohne Benutzerinteraktion aus. Ein anderer Ansatz zur Reduktion des zeitlichen Aufwandes zum Labeling ist die Klassifikation mit fehlerbehafteten Labels. Maas et al. [2018] gehen z.B. von der Existenz einer veralteten Karte der zu klassifizierenden Gebiete aus. Dabei beschreiben die Labels dieser Karte einen ggf. nicht mehr aktuellen Zustand der Bodenbedeckung. Ausgehend davon versucht der Klassifikator, den Einfluss der fehlerhaften Labels im Lernprozess zu kompensieren. Auch diese Methoden unterscheiden sich konzeptionell von der DA, in der keine solche veraltete Karte für das zu klassifizierende Gebiet vorliegt. Diese Methoden können hier deswegen nicht angewendet werden.

Zwei zu der DA nahe verwandte Problemstellungen sind die des Lernens unter dem *Covariate Shift* [Shimodaira, 2000; Sugiyama et al., 2007] und unter dem *Sample Selection Bias* [Zadrozny, 2004; Huang et al., 2007]. Dabei folgen die Trainings- und Testdaten zwar der gleichen Verteilung, die Trainingsdaten sind für diese Verteilung jedoch nicht repräsentativ. Angenommen, es sind gelabelte Trainingsdaten $\overline{TD}' = \{(\mathbf{x}_n, y_n)\}_{n=1}^{N'}$ und ungelabelte Testdaten $\overline{TD}'' = \{(\mathbf{x}_n)\}_{n=1}^{N''}$ vorhanden, die derselben Verteilung folgen. Je nach Ursache ist es nicht immer möglich, die Verteilung $\tilde{p}(\mathbf{x}, y)$ der Trainingsdaten \overline{TD}' so abzuschätzen, dass diese die Verteilung $p'(\mathbf{x}, y)$ korrekt wiedergibt: $\tilde{p}(\mathbf{x}, y) \neq p'(\mathbf{x}, y)$. Das Problem wird als Sample Selection Bias bezeichnet, falls [Bruzzone und Marconcini, 2010]: $\tilde{p}(\mathbf{x}) \neq p'(\mathbf{x})$ und $\tilde{p}(y|\mathbf{x}) \neq p'(y|\mathbf{x})$. Dieser Fall tritt in der Praxis z.B. ein, wenn der Umfang der gesamten Trainingstichprobe nicht groß genug ist oder die Qualität der Trainingsdaten nicht gut genug zur Schätzung der Parameter der Verteilung ist. Das Covariate Shift Problem ist ein Spezialfall von Sample Selection Bias, für das gilt [Bruzzone und Marconcini, 2010]: $\tilde{p}(\mathbf{x}) \neq p'(\mathbf{x})$, wobei $\tilde{p}(y|\mathbf{x}) \approx p'(y|\mathbf{x})$. In der Praxis tritt das Covariate Shift Problem ein, wenn die Trainingsbeispiele nicht zufällig und unabhängig voneinander ausgewählt werden. Das führt dazu, dass die einzelnen Klassen in der gesamten Trainingsstichprobe über- bzw. unterrepräsentiert sind. Eine typische Vorgehensweise bei dieser Art von Problemen ist die

Manipulation der Trainingsdaten durch Resampling (zusätzliche oder wiederholte Auswahl von Trainingsbeispielen) oder durch Gewichtung der Trainingsbeispiele [Quiñonero-Candela, 2009]. Ein weiteres zu DA verwandtes Problem ist das *semi-überwachte Lernen* [Camps-Valls et al., 2007], bei dem ungelabelte Daten (entsprechen der Zieldomäne) zusammen mit gelabelten Trainingsbeispielen (entsprechen der Quelldomäne) zum Lernen herangezogen werden. Allerdings wird hier von der Annahme ausgegangen, dass die Daten dieselbe Verteilung haben. Ein relativ verwandtes Szenario stellen weiterhin die Arbeiten zum *Multitask Lernen* dar [Liu et al., 2009; Leiva-Murillo et al., 2013]. Im Kontext von Multitask Learning spricht man im Allgemeinen von unterschiedlichen aber gleichwertigen Aufgaben, die simultan unter Berücksichtigung der Tatsache gelöst werden, dass die zugehörigen Domänen sich unterscheiden können. Dennoch wird auch hier davon ausgegangen, dass die entsprechenden Randverteilungen der Trainings- und Testdaten gleich sind. Weiterhin wird zur Lösung von solchen Problemstellungen oft auf Trainingsdaten in allen Domänen zugegriffen [Pan und Yang, 2010]. In dieser Arbeit wird jedoch davon ausgegangen, dass die Verteilungen der Trainings- und Testdaten mit $p(\mathbf{x}_S) \neq p(\mathbf{x}_T)$ und $p(y_S|\mathbf{x}_S) \neq p(y_T|\mathbf{x}_T)$ unterschiedlich sind und dass keine Trainingsdaten in der Zieldomäne zur Verfügung stehen. In der Folge sind die angesprochenen Ansätze in diesem Abschnitt nicht auf das vorliegende DA-Problem übertragbar.

3.1.2 Überwachte Domänenadaption

Methoden in dieser Gruppe setzen voraus, dass die gelabelten Daten für Quell- und Zieldomäne zur Verfügung stehen.

Transfer der Merkmalsrepräsentation. Erste Unterkategorie der Verfahren in dieser Gruppe beruht auf der Annahme, dass die Unterschiede zwischen den Verteilungen der Daten aus der Quell- und Zieldomäne durch Projizieren beider Domänen in einen gemeinsamen Merkmalsraum reduziert werden. Eine mögliche Strategie ist z.B. die Auswahl der invarianten Merkmale aus der Menge der vorhandenen Merkmale. Diese Lösung findet in der Fernerkundung eine Anwendung bei Hyperspektralbildern [Bruzzone und Persello, 2009]. Die Autoren nehmen an, dass unter den vorhandenen Merkmalen bereits invariante Merkmale mit guten Diskriminierungseigenschaften vorhanden sind bzw. ohne weitere Voruntersuchungen aus den Merkmalen berechnet werden können. Die Merkmale werden dabei mithilfe einer Optimierungsfunktion selektiert, die aus zwei Termen besteht. Der erste Term dient der Messung des Diskriminierungspotentials gegenüber den betrachteten Klassen. Der zweite Term wertet die Invarianz des Merkmals gegenüber der beiden Domänen aus. Zur Auswertung der Invarianz wird dabei auf gelabelte Daten aus der Quell- und Zieldomäne zugegriffen. Das Optimierungsproblem wird schließlich mit Hilfe der Pareto-Optimierung (en: *multi-objective optimization*) [Fogel, 1995] gelöst. Die aus dem Ansatz resultierende Teilmenge von Merkmalen wird verwendet, um die Klassifikation mit einem ML-Klassifikator durchzuführen. Die Ergebnisse der Evaluierung zeigen die Robustheit des präsentierten Ansatzes bei der Klassifikation räumlich weit ausgedehnter Szenen im Vergleich zu der traditionellen Vorgehensweise ohne Transfer von Merkmalsrepräsentationen. Persello und Bruzzone [2016] stellen eine nichtparametrische, auf Kernels basierende Erweiterung für den

Ansatzes zur Merkmalsauswahl aus [Bruzzone und Persello, 2009] vor. Die zu optimierende Zielfunktion zur Merkmalsauswahl besteht weiterhin aus den zwei Termen. Allerdings wird der Term zur Invarianz zwischen den Domänen als Distanzmaß für die Verschiebung der Verteilungen der Daten aus der Quell- und Zieldomäne gegeneinander im RKHS ausgedrückt und die Messung des Diskriminierungspotentials des anderen Terms erfolgt mit Hilfe des Hilbert–Schmidt Unabhängigkeitskriteriums [Gretton et al., 2005]. Um die besten Merkmale auszuwählen, werden die beiden betrachteten Terme gemeinsam mit dem Algorithmus aus [Bruzzone und Persello, 2009] optimiert. Da die vorgeschlagene Zielfunktion in einem RKHS ausgewertet wird, eignet sich die resultierende Teilmenge der Merkmale für eine anschließende SVM Klassifikation mit derselben Kernfunktion. Experimentelle Ergebnisse auf zwei hyperspektralen Datensätzen bestätigen, dass die vorgeschlagene Technik in der Lage ist, Merkmale auszuwählen, die zu einer verbesserten Generalisierung des Klassifikationsmodells in der Zieldomäne führen, wodurch die Klassifizierungsgenauigkeit gegenüber dem ursprünglichen Ansatz stark erhöht werden kann. Die beiden Methoden sind jedoch speziell für hyperspektrale Fernerkundungsbilder konzipiert und sind nicht ohne Weiteres auf Bilddaten mit wenigen Kanälen übertragbar. Außerdem setzen sie voraus, dass die gelabelten Daten in der Zieldomäne zur Verfügung stehen.

Izquierdo-Verdiguier et al. [2013] verfolgen eine andere Strategie zur Einbeziehung der Domäneninvarianz in den Klassifikationsprozess, und zwar mittels einer Datenerweiterung. Die Autoren passen dafür die Methode von Decoste und Schölkopf [2002] an, deren ursprüngliche Anwendung in der Erkennung von handgeschriebenen Zahlen mit SVM als Klassifikator lag. Sie entwerfen dabei einen gegenüber Rotationen invarianten SVM-Klassifikator, der an die Eigenschaften von Hyperspektraldaten angepasst ist. Dabei soll eine Hyperebene mit besseren Trenneigenschaften konstruiert werden, indem das Vorhandensein von synthetischen Stützvektoren (en: *support vectors*) in den Regionen im Merkmalsraum erzwungen wird, in denen der Klassifikator invariant sein sollte. Mit Hilfe dieser gegenüber Rotationen invarianten Repräsentation wird die Verteilung der Daten aus dem Quelldatensatz an die Verteilung der Daten aus dem Zieldatensatz angepasst. Die Methode selbst besteht aus 3 Schritten. Nach dem Lernen eines SVM Klassifikators auf der Quelldomäne werden neue synthetische Stützvektoren aus den initialen Stützvektoren erzeugt. Anschließend werden originale und synthetische Stützvektoren für das Training des virtuellen SVM-Klassifikators in der Zieldomäne verwendet. Es wird in der Arbeit jedoch nicht auf die Invarianz gegenüber der Translation in den Daten eingegangen, wodurch das Verfahren eine Vereinfachung gegenüber den Annahmen der vorliegenden Arbeit darstellt. Weiterhin benötigt auch diese Methode Labels in der Zieldomäne.

Tuia et al. [2014] verfolgen die Strategie, die Verteilungen der Quell- und Zieldomäne so gut wie möglich an einander anzugleichen, indem deren Merkmalsrepräsentationen in einen gemeinsamen latenten Raum abgebildet werden. Das Verfahren verwendet eine auf Graphen basierende Zuordnung (en: *Graph Matching*), um eine geeignete Abbildungsfunktion zu ermitteln. Es wird dabei je ein Graph für die Daten aus der Quell- und Zieldomäne aufgestellt. Die Knoten des Graphen sind die zugehörigen Stichproben und die Kanten repräsentieren die Ähnlichkeit zwischen den Stichproben in dem Datensatz. Die Stichproben mit ähnlichen Charakteristika bilden Cluster, welche Objekte im Bild repräsentieren. Die beiden Graphen werden anschließend mit Hilfe einer

Manigfaltigkeitsanpassung unter Einbeziehung der Labels aus der Quell- und Zieldomäne aufeinander abgebildet. Dabei bleibt die Topologie der Graphen erhalten. Daraus entsteht eine lineare Transformation, die zum Transfer der Merkmalsrepräsentationen in einen gemeinsamen latenten Raum verwendet wird. Experimente mit synthetischen und realen Daten zeigen vielversprechende Ergebnisse. In [Tuia, 2014] wird die Anforderung nach gelabelten Trainingsdaten unter der Annahme etwas gelockert, dass die Bilddaten der Quell- und Zieldomäne eine gewisse räumliche Überlappung aufweisen. Damit können entsprechende Verknüpfungspunkte (en: *tie points*) identifiziert werden, die die erforderlichen Labels in beiden Domänen bereitstellen. Es wird dabei davon ausgegangen, dass die Pixel an den entsprechenden Stellen in den beiden Domänen dieselbe Klasse aufweisen müssen. Bei der Evaluierung werden dabei die Satellitenbilder einer Region verwendet, die aus unterschiedlichen Winkeln aufgenommen wurden. Nichtsdestotrotz können auch diese Ansätze nicht auf gelabelte Daten in der Zieldomäne bzw. auf Überlappung der Quell- und Zielszene, um daraus Labels für die Zieldomäne ableiten zu können, verzichten.

Transfer von Instanzen. Methoden dieser zweiten Unterkategorie der überwachten DA verwenden Trainingsdaten aus der Quelldomäne zum Lernen des Klassifikators in der Zieldomäne, wobei der Klassifikator sukzessive an die Verteilung der Daten in der Zieldomäne angepasst wird. Ein Beispiel für den überwachten Transfer von Instanzen aus der Textanalyse ist TRADABOOST [Dai et al., 2007], bei dem das Vorhandensein einer geringen Menge an Trainingsdaten aus der Zieldomäne und einer relativ großen Menge an Trainingsdaten aus der Quelldomäne vorausgesetzt wird. Die Grundidee für die Anpassung basiert auf der Verwendung unterschiedlicher Gewichte für die Trainingsbeispiele aus der Quelldomäne. Dabei werden die Trainingsbeispiele der Quelldomäne in zwei Mengen in Bezug auf Ähnlichkeit von deren Verteilung zu der Verteilung der Daten aus der Zieldomäne aufgeteilt. Unter Verwendung von *Boosting* [Schapire, 1990] und Labels in der Zieldomäne wird der Einfluss der Trainingsbeispiele, deren Verteilung sich stark von der Verteilung der Daten aus der Zieldomäne unterscheidet, reduziert, indem deren Gewichte iterativ angepasst werden. Die restlichen Trainingsbeispiele aus der Quelldomäne werden wie zusätzliche Trainingsdaten behandelt, um die Stabilität des erlernten Modells zu erhöhen. Diese Methode wurde allerdings nicht auf Fernerkundungsdaten getestet und sie erfordert eine geringe Menge der Trainingsdaten in der Zieldomäne.

Verfahren zum Transfer von Instanzen wurden auch zur Klassifikation von Fernerkundungsdaten verwendet. Li et al. [2017] schlagen einen auf Kernel-Methoden basierten *iterative reweighting heterogeneous transfer learning* (IRHTL) Ansatz für SVM vor. Die Autoren gehen wie folgt vor. Sie lernen Abbildungsfunktionen für Daten aus der Quell- und Zieldomäne in einen gemeinsamen RKHS durch Minimierung der Risikofunktion der SVM [Vapnik, 1998] und trainieren simultan einen robusten SVM-Klassifikator. Li et al. [2017] schlagen zusätzlich eine iterative Strategie vor, die eine Gewichtung der Trainingsdaten aus der Quelldomäne vorsieht, um die Robustheit der Methode gegenüber den Unterschieden zwischen den Verteilungen der Daten aus der jeweiligen Domäne zu verbessern. Es werden in jeder Iteration zunächst die beiden Abbildungsfunktionen ermittelt und anschließend die Trainingsbeispiele aus der Quelldomäne umgewichtet. Das Gewicht hängt dabei von der Distanz zu der aktuellen Entscheidungsgrenze ab, wobei durch ein Gewicht der Einfluss der Trainingsbeispiele auf die Entscheidungsgrenze reduziert wird, die

weit von dieser Entscheidungsgrenze im gemeinsamen Raum liegen. Li et al. [2017] gehen dabei davon aus, dass die Verteilung solcher Trainingsbeispiele unterschiedlich zu der Verteilung der Stichproben aus der Zieldomäne in einem gemeinsamen Raum ist. Mit dem IRHTL-Ansatz gehen die Autoren unter anderem das Problem der heterogenen Merkmalsräume in der Quell- und Zieldomäne an, wobei die Heterogenität durch die Dimension der Daten (unterschiedliche Anzahl der Bänder) oder durch unterschiedliche Sensoren bedingt sein kann. Die Experimente wurden an drei unterschiedlichen hyperspektralen Fernerkundungsdaten getestet und bestätigen die Effektivität der vorgeschlagenen Methode. Nichtsdestotrotz erfordert die Methode gelabelte Daten in der Zieldomäne. Damit kann das zu behandelnde DA-Problem mit dem vorgestellten Ansatz nicht gelöst werden.

3.1.3 Semi-überwachte Domänenadaption

Diese Gruppe von Methoden geht davon aus, dass die gelabelten Daten nur in der Quelldomäne vorliegen.

Transfer der Merkmalsrepräsentation. Die erste Unterkategorie der Verfahren der semi-überwachten DA, auf die in diesem Abschnitt eingegangen wird, beschäftigt sich mit dem Transfer der Merkmalsrepräsentation. In dem Verfahren von Bruzzone und Persello [2009] aus Kapitel 3.1.2 wird nach räumlich invarianten Merkmalen aus der Menge der vorhandenen Merkmale gesucht, um einen gemeinsamen Merkmalsraum zu finden, in dem die Distanz zwischen den Domänen minimiert wird. Neben dem bereits erläuterten überwachten Ansatz wird auch eine semi-überwachte Vorgehensweise vorgestellt. Während der erste Term der Optimierungsfunktion hiervon nicht betroffen ist, müssen die Parameter des zweiten Terms mit einem ML-Klassifikator auf Basis des *Expectation Maximization* Algorithmus (EM) bestimmt werden. Dabei werden die initialen Parameter des Modells an der Quelldomäne angelernt und auf die Zieldomäne zur Anpassung übertragen. Aufgrund der fehlenden Labels in der Zieldomäne zeigt der semi-überwachte Ansatz bei der Evaluierung etwas schlechtere Ergebnisse gegenüber der überwachten Methode. Die Methode ist jedoch speziell für hyperspektrale Fernerkundungsbilder konzipiert und ist nicht ohne Weiteres auf Bilddaten mit einer geringeren Anzahl an Kanälen übertragbar.

Andere Verfahren in dieser Gruppe verfolgen das Ziel, die Verteilungen der Quell- und Zieldomäne möglichst gut an einander anzugleichen, indem deren Merkmalsrepräsentationen in einen gemeinsamen latenten Raum abgebildet werden. Matasci et al. [2015] verwenden dafür die Transfer Component Analysis (TCA) zur Klassifikation der Landbedeckung aus Fernerkundungsdaten. Ursprünglich von [Pan et al., 2011] zur Textanalyse und WiFi Lokalisierung verwendet, versucht TCA, eine Abbildung über Domänen hinweg im RKHS mit Hilfe der MMD anzulernen. Das Ziel dabei ist, eine Transformationsmatrix für Daten aus der Quell- und Zieldomäne zu bestimmen, die die MMD-Distanz zwischen den beiden Domänen minimiert, wobei die Varianz in den Verteilungen der Daten (Datenstruktur) erhalten bleiben soll. Eine semi-überwachte Variante der Methode wird als SSTCA [Pan et al., 2011] bezeichnet und hilft durch gelabelte Trainingsdaten in der Quelldomäne, die Relationen zwischen den Domänen (durch einen vom Label abhängigen

Term) effektiver anzulernen. In dem resultierenden Unterraum können dann Standardmethoden des maschinellen Lernens angewendet werden, um Klassifikations- oder Regressionsmodelle domänenübergreifend zu trainieren bzw. anzuwenden. Das Verfahren hat jedoch Schwierigkeiten, die Datenstruktur beizubehalten, wodurch die Trennbarkeit von einigen Klassen durch die Transformation beeinträchtigt wird. Ein ähnlicher Ansatz zur Verbesserung der Generalisierung von Merkmalsrepräsentationen und Reduktion der Distanz zwischen den Domänen im RKHS mit Hilfe von MMD wird in [Sun et al., 2016] vorgestellt. Die Autoren schlagen ein TSSA-Algorithmus (en: *Transfer Sparse Subspace Analysis*) vor, um semantisches Wissen, das aus terrestrischen Aufnahmen gewonnen wurde, auf hochauflösende Fernerkundungsaufnahmen (Satellitenbilder) zu übertragen. Es wird jedoch eine Aussage für die ganze Szene getroffen, ob ein bestimmtes Objekt vorliegt oder nicht, es folgt daraufhin keine Lokalisierung der Objekte.

In [Gopalan et al., 2011] werden die Daten der Quell- und Zieldomäne auf Unterräume niedriger Dimension projiziert. Die Projektionen bilden zwei Punkte aus einer Graßmann-Mannigfaltigkeit [Lee, 2010], zwischen denen weitere Unterräume entlang einer geodätischen Linie gesucht werden. Die Projektionen der Daten auf diese Zwischen-Unterräume liefern neue transformierte Merkmale, welche unter anderem für eine semi-unüberwachte Klassifikation verwendet werden. Gong et al. [2012] gehen ähnlich vor, vermeiden jedoch die explizite Projektion durch Verwendung von Kernfunktionen. Das Ziel liegt jedoch wie in Gopalan et al. [2011] in der Aussage, ob in einem Bild (keine Fernerkundungsdaten) ein bestimmtes Objekt vorliegt oder nicht, es erfolgt keine Lokalisierung der Objekte. Ein auf Graphen basierender Ansatz zur Klassifikation von zeitlich und räumlich disjunkten hyperspektralen Fernerkundungsdaten wird in [Yang und Crawford, 2016] verfolgt. Es wird dabei je ein Graph für die Daten aus der Quell- und Zieldomäne ähnlich wie in [Tuia et al., 2014] aufgestellt. Damit wird eine Abbildungsfunktion bestimmt, die die Merkmale der beiden Domänen in einen gemeinsamen Raum transformiert. Es wird dabei angenommen, dass die intrinsischen lokalen Strukturen der entsprechenden Klassen aus beiden Domänen ähnlich sind und durch die Transformation erhalten bleiben. Die Untersuchung der Geometrien im Graph basiert auf [Yan et al., 2007]. In [Yang und Crawford, 2016] wenden die Autoren eine neue Technik namens GALM (en: *globally align local manifolds*) an, die Graphen durch eine Transformation aneinander anpasst. Das Verfahren ist jedoch sehr komplex, wodurch die Rechenzeit stark mit der Anzahl der Stichproben zunimmt.

Transfer von Instanzen. Methoden dieser Unterkategorie der semi-überwachten DA zum Transfer von Instanzen verwenden Trainingsdaten aus der Quelldomäne zum Lernen des Klassifikators in der Zieldomäne, wobei der Klassifikator sukzessive an die Verteilung der Daten in der Zieldomäne angepasst wird. Der in dieser Arbeit verfolgte semi-überwachte DA-Ansatz basiert auf dem Transfer von Instanzen. Aus diesem Grund stehen die Verfahren aus dieser Kategorie im Fokus dieses Kapitels.

Eine große Gruppe beim Transfer von Instanzen bilden die Verfahren, die von einem Gaußschen Mischmodell (en: *Gaussian Mixture Modell*, GMM) als Modell für die Verteilung der Daten ausgehen [Bruzzone und Prieto, 2001, 2002; Rajan et al., 2006; Bahirat et al., 2012]. In dem von Bruzzone und Prieto [2001] vorgeschlagenen semi-überwachten Ansatz liegen zwei Bilder aus unterschiedlichen Epochen eines und desselben Gebietes vor. Trainingsdaten existieren dabei nur

für den ersten Zeitpunkt (Quelldomäne), während es für die spätere Aufnahme (Zieldomäne) keine Trainingsdaten vorhanden sind. Als Basisklassifikator dient der ML-Klassifikator. Die Verteilung der Daten aus der Zieldomäne wird dabei als GMM modelliert. Zu Beginn werden die Gauß-Modelle mit dem Klassifikator aus den gelabelten Daten der Quelldomäne angelernt. Anschließend werden die Komponenten eines GMM in der Zieldomäne mit den angelernteten Gauß-Modellen initialisiert und mit Hilfe des EM-Algorithmus verbessert. Am Ende des iterativen Prozesses stehen angepasste Parameter für jede Komponente des Mischmodells fest, die zur Schätzung der Klassenzugehörigkeit der Zieldaten (die von den ursprünglichen Komponenten übernommen wird) dienen. Die Evaluierung der Methode auf zwei Bildern aus unterschiedlichen Epochen zeigt eine wesentliche Verbesserung der Klassifikationsgenauigkeit verglichen zu dem Fall ohne Adaption und gleicht der Genauigkeit, die erreicht wird, wenn der Klassifikator auf der Zieldomäne trainiert und getestet wird. Die Autoren merken jedoch an, dass die Methode auf Basis von EM zu falschen Ergebnissen führen kann, falls die geschätzten initialen Parameter für das Gaußsche Mischmodell sich zu stark von den richtigen Parameter des Mischmodells aus der Zieldomäne, z.B. bedingt durch Saisonale Effekte oder Lichtverhältnisse, unterscheiden. Der vorherige ML-basierte Ansatz zur DA wird in [Bruzzone und Prieto, 2002] durch den Kaskaden-Klassifikationsansatz (en: *cascade classifier*) [Swain, 1978] fürs Gaußsche Mischmodelle erweitert. Der erweiterte Ansatz erlaubt, die Informationen aus der Quell- und Zieldomäne gemeinsam im Klassifikationsprozess zu berücksichtigen. Die Klassifikation der Zieldaten beinhaltet im Unterschied zu [Bruzzone und Prieto, 2001] die Schätzung der klassenbedingten Dichten in der Quell- und Zieldomäne, sowie eine gemeinsame Wahrscheinlichkeit für jedes Klassenpaar der Quell- und Zieldomäne, die für einen Kaskaden-Klassifikator notwendig sind. Der Term mit der gemeinsamen Wahrscheinlichkeit für jedes Klassenpaar ermöglicht die Einbeziehung von zusätzlichem a-priori Wissen in den Adaptionsprozess, welches eine zeitliche Entwicklung für eine oder mehrere Klassen beinhaltet. Allerdings muss diese a-priori Information vom Benutzer vorgegeben werden. Andernfalls, wenn solche Informationen nicht vorliegen, wird von der gleichen Wahrscheinlichkeit für alle Klassenpaare ausgegangen. Der Ansatz ist wiederum für multitemporale Fernerkundungsdaten konzipiert und wurde auf den Datensätzen aus [Bruzzone und Prieto, 2001] getestet. Dabei zeigt er zu [Bruzzone und Prieto, 2001] etwa die gleiche Klassifikationsgenauigkeit bei einem leichten Anstieg der Genauigkeit für die Klassen, für die das a-priori Wissen vorhanden war. Abgesehen davon, dass der Ansatz für multitemporale Fernerkundungsdaten entwickelt wurde, liegt eine wesentliche Beschränkung der Methode darin, dass diese multitemporalen Daten zu ähnlichen Jahreszeiten aufgenommen werden müssen [Bruzzone und Prieto, 2002]. Diese Bedingung stellt eine Beschränkung in Bezug auf die Erfassung der Daten und Verteilung der Merkmalsvektoren in der Quell- und Zieldomäne dar, die in der vorliegenden Arbeit nicht gegeben ist. Schließlich wird in [Bruzzone et al., 2002; Bruzzone und Cossu, 2002] der Ansatz aus [Bruzzone und Prieto, 2002] auf einen Klassifikator auf Basis eines RBF-neuronalen-Netzwerks (en: *radial basis function neural network*) erweitert. Die Methode basiert auf der Annahme, dass die Schätzungen der Klassifikationsparameter, die aus einem überwachten Training auf der Quelldomäne abgeleitet wurden, grobe Schätzungen der Klassenverteilungen in dem zu klassifizierenden Zielbild erlauben. Zur Lösung des DA-Problems wird hier ein Ensemble der Kaskaden-Klassifikatoren verwendet, um die Genauigkeit und Ro-

bustheit der Methode gegenüber einem einzelnen Klassifikator zu verbessern. Als Klassifikatoren werden hier der ML-Klassifikator, ein RBF-neuronales-Netz und ein Kaskaden-Klassifikator verwendet, wobei der EM-Algorithmus weiterhin zur Schätzung der Komponenten des jeweiligen GMM eingesetzt wird. Experimentelle Ergebnisse an einem realen multitemporalen Datensatz zeigen die Wirksamkeit der vorgeschlagenen Methode. Allerdings ist die Evidenz für eine Wirksamkeit der Methode ausgehend von den Experimenten an zwei Bildern aus unterschiedlichen Epochen durchaus nicht eindeutig.

In Rajan et al. [2006] wird eine DA-Methode zur Klassifikation von multitemporalen und räumlich disjunkten Fernerkundungsdaten auf Basis von binären hierarchischen Klassifikatoren (en: *binary hierarchical classifier*: BHC) vorgestellt. BHC [Kumar et al., 2002] ist ein modulares Lernsystem, das aus einer automatisch generierten binären Hierarchie (Baumstruktur) von Klassifikatoren besteht, die jeweils ein Zwei-Klassen-Problem lösen und über einen eigenen Merkmalsraum verfügen. Ein Mehrklassenproblem mit K Klassen (entspricht der Anzahl der Blätter) wird dabei rekursiv in $(K - 1)$ binäre Probleme zerlegt, was zu $(K - 1)$ Klassifikatoren (entspricht der Anzahl der Knoten) führt. Die Merkmale werden dabei mit dem *Fisher Extraktor* [Fisher, 1936] für einen binären Klassifikator in dem jeweiligen Knoten separat extrahiert. Die Idee hinter dem Ansatz ist, die Parameter des BHC-Baumes, der an den Daten der Quelldomäne trainiert wurde, auf Basis der Verteilung der Daten in der Zieldomäne zu aktualisieren. Dafür wird zunächst ein BHC-Baum unter Verwendung der gelabelten Trainingsdaten aus der Quelldomäne generiert. Ein solcher Baum bildet gleichzeitig die Hierarchie der Klassen der Quell- und Zieldomäne ab. Dann werden die jeweiligen Fisher-Merkmalsextraktoren und die entsprechenden binären Klassifikatoren unter Berücksichtigung der Verteilung der Daten in der Zieldomäne aktualisiert. Dies geschieht mit Hilfe des EM, bei dem die Trainingsdaten der Quelldomäne zur Initialisierung des Algorithmus verwendet werden. Um die Robustheit der Methode gegenüber unterschiedlichen Verteilungen in der Zieldomäne zu verbessern, wird ein Ensemble von BHC-Bäumen erzeugt sowie auf Randomisierung der Baumstruktur gesetzt. Bei der Randomisierung wird ein interner Knoten ausgewählt und die Klassen seinen rechten und linken Kinder zufällig vertauscht. Es wird auch eine überwachte Erweiterung vorgeschlagen, in der die Klassifikatoren, die bei gegebenen gelabelten Daten aus der Zieldomäne schlecht abschneiden, niedriger gewichtet werden. Experimentelle Ergebnisse zeigen, dass der vorgeschlagene Ansatz besser als eine direkte Anwendung des ursprünglichen Klassifikators auf die neuen Daten ist. Die Schwachstelle der Methode ist die Initialisierung des EM-Algorithmus auf Basis der Trainingsdaten der Quelldomäne. Dies kann zu einer starken Verfälschung der Ergebnisse führen, falls die geschätzten initialen Parameter sich zu stark von den tatsächlichen Parametern des Modells aus der Zieldomäne unterscheiden. Außerdem kann die Methode in einer schlechten Qualität der Anpassung resultieren, falls die Menge der Stichproben aus der Quell- und Zieldomäne nicht groß genug ist.

Bahirat et al. [2012] befassen sich mit dem Problem der Aktualisierung von Landbedeckungskarten aus multitemporalen Fernerkundungsbildern mit Hilfe der DA. Dabei sind gelabelte Trainingsdaten für eine der betrachteten multitemporalen Aufnahmen (Quelldomäne), nicht aber für die spätere Aufnahme (Zieldomäne) verfügbar. Es wird ein Ansatz zur Lösung des DA-Problems mit dem *Bayesschen Klassifikator* auf der Grundlage der MAP-Entscheidungsregel, kurz DA-MAP

genannt, vorgeschlagen. DA-MAP initialisiert das Adaptionsverfahren und aktualisiert die Komponenten eines GMM unter Verwendung des EM-Algorithmus. Der wesentliche Unterschied zu den anderen Verfahren besteht darin, dass die multitemporalen Aufnahmen eine unterschiedliche Klassenstruktur haben können. Dafür wird die Technik der *change vector analysis* [Singh, 1989] angewendet, um eines von vier möglichen Szenarios festzustellen, nämlich ob neue Klassen in der Zieldomäne erschienen sind und/oder einige der in der Quelldomäne bestehenden Klassen verschwunden sind oder gar keine Änderung in der Klassenstruktur festgestellt werden kann. Die Fallunterscheidung erfolgt mit Hilfe des *Jeffries-Matusita*-Distanzmaßes. Erste experimentelle Ergebnisse bestätigten die Effektivität des vorgeschlagenen DA-MAP-Klassifikators. Es wird jedoch eine hohe Korrelation (Ähnlichkeit) zwischen denselben Klassen aus den beiden Domänen erwartet, damit die Adaption für die Domänen mit einer unterschiedlichen Klassenstruktur Sinn ergibt. Außerdem geht der Ansatz davon aus, dass es Daten aus zwei verschiedenen Zeitpunkten eines und derselben Gebietes vorliegen.

Eine Vielzahl von Verfahren zur DA mit Transfer von Instanzen basiert weiterhin auf Kernel-Methoden [Bruzzone und Marconcini, 2010; Sun et al., 2013; Gomez-Chova et al., 2008; Kim und Crawford, 2010]. Bruzzone und Marconcini [2009, 2010] stellen einen semi-überwachten Ansatz zur DA auf Basis von SVM vor. Dafür wird der iterative Algorithmus aus [Bruzzone et al., 2006], der ursprünglich für Fernerkundungsprobleme mit limitierter Quantität und Qualität von Trainingsdaten entwickelt wurde, auf DA-Problemstellungen erweitert, in denen die Domänen sich durch Randverteilungen der Merkmale und a-posteriori Wahrscheinlichkeiten der Klassen unterscheiden dürfen. Die neue vorgeschlagene DA-Technik wird kurz als DASVM bezeichnet. Ausgangslage bildet ein initialer SVM-Klassifikator, der an den gelabelten Daten aus der Quelldomäne trainiert wurde. Anschließend werden den ungelabelten Daten der Zieldomäne die Semi-Labels basierend auf dem aktuellen Stand des Klassifikators vergeben. Danach wird eine Teilmenge der semi-gelabelten Trainingsdaten aus der Zieldomäne ausgewählt und zur Menge der Trainingsbeispiele aus der Quelldomäne iterativ hinzugefügt, während eine gleiche Anzahl an Trainingsbeispielen aus der Quelldomäne weggelassen wird, um einen hybriden Trainingssatz für die nächste Iteration zu bilden. Der SVM-Klassifikator wird in jeder Iteration an dem aktualisierten hybriden Trainingssatz neu trainiert. Auf diese Weise wird der Klassifikator sukzessive an die Verteilung der Daten in der Zieldomäne angepasst, sodass der endgültige Klassifikator nur auf Basis der semi-gelabelten Trainingsdaten aus der Zieldomäne trainiert wird. Das Kriterium zur Auswahl der Stichproben aus der Quell- und Zieldomäne zur Aktualisierung des hybriden Trainingsdatensatzes basiert auf einem auf Basis von SVM entwickelten Distanz-Kriterium, welches sich auf den Abstand der Stichproben zur aktuellen Trennebene (Entscheidungsgrenze) bezieht. Dabei werden die gelabelten Stichproben der Quelldomäne aus dem hybriden Trainingsdatensatz entfernt, die am weitesten von der Trennebene liegen, während jene semi-gelabelten Stichproben der Zieldomäne zu dem hybriden Trainingsdatensatz hinzugefügt werden, die am nächsten zum Rand des Trennbereichs (en: *margin*) liegen. Die Methode wurde unter anderem an zwei Satellitenaufnahmen eines Gebietes aus unterschiedlichen Epochen evaluiert. Dabei zeigt DASVM ein gutes Anpassungsverhalten und ist unter den optimalen Parametereinstellungen dem Ansatz aus [Bruzzone und Prieto, 2001] überlegen. Dennoch ist SVM ein komplexer, vergleichsweise langsamer und speicherintensiver Klassifikator [Abe, 2010]. Darüber hinaus ist die Evidenz für

eine Wirksamkeit dieser DA-Methode ausgehend von den Experimenten an zwei Bildern aus unterschiedlichen Epochen durchaus nicht umfassend.

Die Idee hinter dem auf Kernel-Methoden basierten Ansatz aus [Sun et al., 2013] ist, die Informationen über die Verteilung der Daten aus der Quelldomäne zur Anpassung des SVM-Klassifikators an die Zieldomäne zu nutzen. Sun et al. [2013] wenden dafür einen semi-überwachten Ansatz, das *domain transfer multiple-kernel learning* (DTMKL) [Duan et al., 2012], auf DA Probleme an. DTMKL verfolgt das Ziel, den Abstand zwischen den Datenverteilungen der beiden Domänen nach einer Transformation in einen RKHS zu minimieren und gleichzeitig einen robusten Klassifikator zu erlernen. In der Praxis bedeutet das, dass die DTMKL-Optimierungsfunktion aus zwei Termen besteht: Der erste Term beschreibt einen Distanzmaß zwischen den Datenverteilungen in RKHS mit Hilfe der MMD, der zweite Term dient der Minimierung der Risikofunktion (en: structural risk function) von SVM [Vapnik, 1998] für eine bessere Klassifikation in der Zieldomäne. Die Risikofunktion wird dabei mit Hilfe der Daten der Quelldomäne erstellt und für den RKHS durch die Minimierung der DTMKL-Optimierungsfunktion angepasst. Damit kann dieser Framework für jedes kernelbasierte Klassifikationsverfahren angewandt werden, was gleichzeitig auch ein Limitierungsaktor ist. Sun et al. [2013] nutzen in ihrer Arbeit SVM im Rahmen des DTMKL-Frameworks. Die Ergebnisse der Tests an zwei realen hyperspektralen Datensätzen zeigen gute Klassifikationsgenauigkeit und Robustheit der Methode gegenüber den Änderungen in den Verteilungen der beiden Domänen. Die Experimente behandeln jedoch nur die Adaption zwischen räumlich disjunkten Regionen des jeweiligen Datensatzes. Damit bleiben z.B. die saisonale Effekte oder Lichtverhältnisse in den Experimenten unberücksichtigt. Außerdem ist das Verfahren relativ komplex, wodurch die Rechenzeit stark mit der Anzahl der Stichproben zunimmt.

In [Leiva-Murillo et al., 2013] präsentieren die Autoren das DA Problem als ein Multitask Learning Problem zur Klassifikation von Fernerkundungsdaten mit SVM. Im Kontext von Multitask Learning spricht man im Allgemeinen von unterschiedlichen aber gleichwertigen Aufgaben, die gleichzeitig gelöst werden, wobei die zugehörigen Domänen sich unterscheiden können. Die Anpassung erfolgt hier mit der Modifikation des Kernels durch den Austausch von Informationen zwischen den Domänen. Leiva-Murillo et al. [2013] spalten den Parametervektor einer SVM in Komponenten auf, von denen manche von mehreren Aufgaben geteilt werden und andere spezifisch für die jeweilige Aufgabe sind. Das Training verläuft ähnlich dem einer SVM, allerdings mit einer modifizierten Kernel-Funktion. Experimente wurden unter anderem an multitemporalen und räumlich disjunkten Fernerkundungsdaten durchgeführt. Die erzielten Ergebnisse zeigen die Effektivität des Ansatzes im Vergleich zu anderen untersuchten Kernel-Methoden des traditionellen maschinellen Lernens. Jedoch geht die vorliegende Arbeit von unterschiedlichen Voraussetzungen im Vergleich zu [Leiva-Murillo et al., 2013] (Multitask Learning) aus, wo gleiche Randverteilungen der Daten aus der Quell- und Zieldomäne angenommen werden.

Acharya et al. [2012] stellen ein semi-überwachtes Verfahren vor, das auf der Kombination von *Ensembles of Classifiers and Clusterers* [Acharya et al., 2011], kurz C^3E , basiert und speziell für TL angepasst wurde. Unter 'Ensembles of Clusterers' versteht man ein Verfahren, in dem eine Reihe von Clustering-Algorithmen auf einen Datensatz mit dem Ziel angewendet wird, eine Lösung zu dem Clustering-Problem zu erhalten, die genauere Cluster als die jeweiligen einzelnen

Algorithmen liefert. Der für die DA angepasste C^3E -Ansatz nimmt am Eingang einen oder mehrere an der Quelldomäne angelernete Klassifikatoren sowie eine konsolidierte Lösung des Ensembles von Clustering-Algorithmen für die Zieldomäne und liefert am Ausgang eine Entscheidung über Klassenzugehörigkeiten der Zieldaten. Die Experimente zu dem C^3E -Ansatz enthalten auch ein Beispiel aus der Fernerkundung. Eine empirische Evaluierung mit multitemporalen, hyperspektralen Daten zeigt vielversprechende Ergebnisse der vorgeschlagenen Methode im Vergleich zu den anderen untersuchten Lerntechniken. Das Verfahren ist jedoch relativ komplex, womit die Rechenzeit entsprechend der Anzahl der Algorithmen im Ensemble zunimmt. Außerdem wurden für die Anwendung in der Fernerkundung einfache Basisklassifikatoren wie Naives Bayes und ML verwendet.

Zhang et al. [2010] stellen eine Methode für TL auf Basis der LR, nämlich *transductive transfer learning from multiple sources* (TTLRM) vor. Die Voraussetzung für den Ansatz ist die Verfügbarkeit von mehreren Quelldomänen, die gelabelte Daten beinhalten, und einer Zieldomäne mit ungelabelten Daten, die klassifiziert werden sollen. Die Idee hinter dem vorgeschlagenen Ansatz basiert darauf, die Trainingsbeispiele aus den vorhandenen Quellen nach deren Ähnlichkeit zu den Daten aus der Zieldomäne zu sortieren und abhängig davon Gewichte für alle Trainingsdaten aus der jeweiligen Quelldomäne zu vergeben. Auf den gewichteten Trainingsdaten aus allen Quelldomänen wird anschließend ein Klassifikator antrainiert, der robuster gegenüber einer unterschiedlichen Verteilung der Daten in der Zieldomäne ist. Um die Ähnlichkeit der Trainingsbeispiele aus den vorhandenen Quelldomänen zu den Daten aus der Zieldomäne quantitativ erfassen zu können, kommt wiederum die LR zum Einsatz. Dabei werden Stichproben aus mehreren vorhandenen Quelldomänen und der Zieldomäne in einem vermischten Trainingsdatensatz zusammengefasst, wobei die Labels neu nach der jeweiligen Quell- bzw. Zieldomäne vergeben werden und diese eindeutig identifizieren. Dann wird die LR für Mehrklassenprobleme auf diesem vermischten Trainingsdatensatz antrainiert. Anschließend werden ausgehend von der bedingten Wahrscheinlichkeiten des jeweiligen Trainingsbeispiels für die Klasse, die mit der Zieldomäne assoziiert wird, die Gewichte für alle Trainingsbeispiele aus den ursprünglich vorhandenen Quelldomänen vergeben. Die Methode wird an einem Datensatz zur Sentiment-Analyse (Bereich der Text Data Mining) mit nur zwei möglichen Klassen getestet. Die Experimente mit TTLRM zeigen eine gute Klassifikationsgenauigkeit gegenüber anderen Klassifikatoren ohne Anpassung. Es wird jedoch nur eine binäre Klassifikation untersucht, die weder auf Fernerkundungsdaten noch auf anderen Bilddaten getestet wurde. Weiterhin gehen die Autoren von der Annahme aus, dass die Domänen zwar ähnlich sind, sich jedoch nur in den Randverteilungen der Merkmale unterscheiden können. Außerdem verfolgt der in der vorliegenden Arbeit vorgeschlagene Ansatz eine andere iterative Strategie, die sowohl Trainingsdaten aus der Quell- und Zieldomäne umfasst als auch die Semi-Labels der Zieldomäne einbezieht.

3.1.4 Unüberwachte Domänenadaption

Der Vollständigkeit halber muss auch die unüberwachte DA erwähnt werden. Diese Ansätze sind für diese Arbeit jedoch weniger relevant, weil sie in keiner Domäne gelabelte Daten voraussetzen. Damit sind solche Verfahren in der Hinsicht beeinträchtigt, dass sie zur Klassifikation der Daten eine Interaktion des Benutzers oder a-priori Wissen erfordern. Aus diesem Grund verfolgen die meisten Ansätze zur unüberwachten DA in der Fernerkundung nur das Ziel, die Verteilungen aus den beiden Domänen aneinander anzugleichen. Im Ansatz von [Matasci et al., 2015], der bereits in Kapitel 3.1.3 erwähnt wurde, wird zum Zwecke der Klassifikation der Landbedeckung aus Fernerkundungsdaten dafür die TCA-Technik angewendet. TCA versucht eine Abbildung über Domänen hinweg in einen gemeinsamen Raum (RKHS) mit Hilfe der MMD anzulernen. Das Ziel dabei ist, eine Transformationsmatrix für Daten aus der Quell- und Zieldomäne zu bestimmen, die die MMD-Distanz zwischen den beiden Domänen minimiert, wobei die Varianz in den Verteilungen der Daten erhalten bleiben soll. Eine Klassifikation kann anschließend z.B. unter Einbeziehung der Labels in der Quell- oder Zieldomäne durchgeführt werden. Tuia et al. [2013] verwenden eine auf Graphen basierende Zuordnung zusammen mit Clustering von Merkmalsräumen, um eine geeignete Abbildungsfunktion für die Daten aus der Quelldomäne auf unüberwachte Weise zu ermitteln. Mit der gesuchten Abbildungsfunktion soll die Verteilung der Daten aus der Quelldomäne möglichst gut an die Verteilung der Daten aus der Zieldomäne angeglichen werden. Es wird dabei je ein Graph für die Daten aus der Quell- und Zieldomäne aufgestellt. Die Knoten des Graphen sind die Cluster-Zentroide und die Kanten repräsentieren über den Abstand zwischen den Cluster-Zentroiden in einem gemeinsamen Raum lokale Nachbarschaftsbeziehungen. Die beiden Graphen werden anschließend mit Hilfe einer Manigfaltigkeitsanpassung aufeinander abgebildet. Die Optimierungsfunktion besteht dabei aus zwei Termen: ein Term wertet die Verschiebung der entsprechenden Cluster-Zentroide aus, die klein gehalten werden soll, und der andere Term dient der Beibehaltung der Struktur des jeweiligen Graphen. Experimente mit synthetischen und realen Daten zeigen vielversprechende Ergebnisse. Eine Klassifikation erfordert jedoch auch hier gelabelte Daten in der Quelldomäne.

3.1.5 Deep Domain Adaptation

Methoden des *Deep Learnings* (DL) finden in den letzten Jahren eine weite Verbreitung in der wissenschaftlichen Literatur im Bereich des maschinellen Lernens [Yosinski et al., 2014; Rusu et al., 2016; Bejiga und Melgani, 2018]. DL-Methoden werden auch im Bereich der Fernerkundung eingesetzt (vgl. [Zhu et al., 2017]). Auch im Bereich des DL werden die Methoden der DA, als *Deep Domain Adaptation* (DEEP DA) bezeichnet, eingesetzt. Dabei sind die Methoden zur DA auf Basis von CNNs stark verbreitet. Typischerweise kommt für CNN-basierte Ansätze der Transfer der Merkmalsrepräsentationen zum Einsatz [Wang und Deng, 2018]. Dabei wird versucht, eine gegen möglichst viele Einflüsse invariante Repräsentation in einem Merkmalsraum zu finden, damit eine anschließende Klassifikation möglichst unabhängig von der jeweiligen Domäne stattfinden kann. Eine verbreitete Umsetzung dieser Idee basiert auf dem Umtrainieren (en: *Re-Training*) des existierenden neuronalen Netzes [Yosinski et al., 2014; Wang und Deng, 2018].

Dafür wird zunächst ein neuronales Netz an den gelabelten Daten aus der Quelldomäne antrainiert. Dann wird die letzte Schicht des an den Daten der Quelldomäne vortrainierten Netzes durch die Schicht zur Prädiktion der Labels in der Zieldomäne ersetzt. Dabei werden die Parameter des neuronalen Netzes unter Verwendung von gelabelten Daten aus der Zieldomäne angepasst bzw. das neuronale Netz wird damit umtrainiert, wobei die ersten Schichten des Netzes „eingefroren“ werden, d.h. konstant gehalten werden (vom Umtrainieren ausgeschlossen). Yosinski et al. [2014] stellen dabei fest, dass zu viele „eingefrorene“ Schichten die Qualität der Klassifikation beeinträchtigen, während das Umtrainieren mehrerer Schichten mehr Trainingsdaten in der Zieldomäne erfordert. Semi-überwachte Methoden zur DEEP DA auf Basis von CNNs, in denen die gelabelten Daten nur in der Quelldomäne zur Verfügung stehen, kommen in der Literatur auch vor [Goodfellow et al., 2014; Hoffman et al., 2018; Tzeng et al., 2017]. Allerdings beschäftigen sich nur wenige Arbeiten mit der pixelweisen Klassifikation (semantische Segmentierung) der Bilder [Wang und Deng, 2018]. Methoden zur pixelweisen Klassifikation wurden auf Basis der sogenannten *fully convolutional neural networks* [Long et al., 2015] entwickelt. DEEP DA Methoden zur pixelweise Klassifikation finden auch in der Fernerkundung eine Anwendung, z.B. in [Wittich und Rottensteiner, 2019].

Schließlich gibt es im Bereich DEEP DA Arbeiten, die sich mit den anderen Methoden als CNNs beschäftigen. Othman et al. [2016] schlagen z.B. ein dreischichtiges konvexes Netz (en: *convex network*), das als 3CN bezeichnet wird, für multitemporale, sehr hochauflösenden (VHR) Fernerkundungsbilder vor. Dafür werden zuerst entsprechende Verknüpfungspunkte in den gelabelten Bilddaten aus der Quelldomäne und ungelabelten Bilddaten aus der Zieldomäne extrahiert und einander zugeordnet. Dann werden die gelabelten Pixel in die Zieldomäne projiziert und zum Trainieren eines Klassifikators darin verwendet. Zur Realisierung des Ansatzes kommt 3CN zum Einsatz. Dessen erste Schicht dient der Regression und bildet die Trainingsbeispiele aus der Quelldomäne auf die Zieldomäne ab. Die zweite Schicht dient der Klassifikation der Bilddaten aus der Zieldomäne. Die ersten beiden Schichten sind über ein einschichtiges feedforward-neuronales-Netz (en: *feedforward neural network*) realisiert, das als *Extreme Learning Machine* (ELM) bezeichnet wird. Schließlich dient die dritte Schicht der räumlichen Regularisierung auf Basis des Random-Walker-Algorithmus [Lawler und Limic, 2010]. Das Verfahren wird auf multitemporalen VHR-Fernerkundungsbilder von IKONOS-2 und GeoEye-1 getestet und zeigt bessere Ergebnisse im Vergleich zu den anderen untersuchten DA-Ansätzen. Das Verfahren kann jedoch nicht auf räumlich disjunkte Szenen angewendet werden, da es auf die Zuordnung der Verknüpfungspunkte angewiesen ist.

Trotz der Überlegenheit der Methoden der DEEP DA in Bezug auf Klassifikationsgenauigkeit brauchen sie sehr viele Trainingsdaten in der Quelldomäne [Wang und Deng, 2018], welche in dieser Arbeit nicht gegeben sind.

3.1.6 Umgang mit negativem Transfer

Die Leistungsfähigkeit der DA hängt von der Ähnlichkeit der Quell- und Zieldomäne ab. Eine unzureichende Ähnlichkeit kann sich negativ auf die Übertragung vom Wissen auswirken

[Rosenstein et al., 2005]. Die negativen Auswirkungen können sogar zu einer Verringerung der Genauigkeit nach der DA im Vergleich zu dem Fall, in dem Klassifikator direkt nach dem Training anhand von Daten aus der Quelldomäne zur Klassifikation auf die Zieldomäne angewendet wird, führen. Man spricht dann von einem NT. In diesem Abschnitt werden einige der wenigen vorhandenen Arbeiten aus dem Bereich der Vermeidung bzw. Prädiktion von NT kurz vorgestellt. Die Erkennung und Vermeidung von NT lässt sich beim induktiven TL unkompliziert gestalten. Hier können die in der Zieldomäne verfügbaren gelabelten Daten direkt zur Validierung eingesetzt werden. Rosenstein et al. [2005] zeigen, dass für einen hierarchischen Naiven Bayes-Klassifikator die Gefahr vom NT mit einer zunehmenden Anzahl der gelabelten Daten in der Zieldomäne abnimmt. Es ist jedoch schwierig, ein gutes Maß für die Ähnlichkeit zwischen Quell- und Zieldomäne zu finden oder eine robuste Methode zur Vorhersage eines NT für die semi-überwachte DA zu definieren.

Eine erste Gruppe von Verfahren versucht, die Ähnlichkeit zwischen den Domänen mit Hilfe eines Maßes zu erfassen, dessen Wert zur weiteren Handlung, z.B. Vermeidung oder Prädiktion von NT, verwendet wird. In [Persello und Bruzzone, 2016] (siehe auch Kapitel 3.1.2) wird ein Ähnlichkeitsmaß im Rahmen der verwendeten Optimierungsfunktion verwendet. Persello und Bruzzone [2016] stellen dabei für die DA ein kernelbasiertes Merkmalsauswahlverfahren für hyperspektrale Daten vor. Die Optimierungsfunktion zur Auswahl der Merkmale beinhaltet einen Term zur Invarianz zwischen den Domänen, der auf einem Distanzmaß für die Verteilungen der Daten aus der Quell- und Zieldomäne im RKHS basiert. Damit könnte es zur Erkennung von NT eingesetzt werden. Das Potential des Distanzmaßes wurde in [Persello und Bruzzone, 2016] an einem einfachen synthetischen Beispiel gezeigt. Die Berechnung des Distanzmaßes erfordert jedoch eine gewisse Menge an gelabelten Daten in der Zieldomäne [Persello und Bruzzone, 2016], welche in der vorliegenden Arbeit nicht verfügbar sind.

Vogt et al. [2018] verwenden ein Ähnlichkeitsmaß zur Auswahl einer oder mehrerer Quelldomänen, die zu der vorhandenen Zieldomäne ähnlich sind, um so den NT zu vermeiden. Die Strategie zur Auswahl einer oder mehrerer der Zieldomäne ähnlichen Quelldomänen wird als *Quellenselektion* bezeichnet. Bei dieser Strategie wird davon ausgegangen, dass unter den vorhandenen Quellen bereits solche gibt, die der Zieldomäne relative ähnlich sind. Der Einsatz der Quellenselektion knüpft damit an die Bedingung der Verfügbarkeit einer relativ umfangreichen Datenbank mit gelabelten Daten aus mehreren Quellen an. Die Bereitstellung einer solchen Datenbank kann jedoch für reale Anwendungen unmöglich sein. Quellenselektion wird in [Vogt et al., 2018] im Rahmen der DA auf Basis von Instanzentransfer vorgeschlagen. Dabei werden keine gelabelten Daten in der Zieldomäne benötigt. Die Autoren schlagen ein Ähnlichkeitsmaß zwischen den Merkmalsverteilungen verschiedener Domänen vor, das auf der MMD von Gretton et al. [2012] basiert. Dieses Ähnlichkeitsmaß wird als Distanz zwischen zwei Domänen interpretiert und dient der Aufgabe, jene Quelldomänen zu finden, die der untersuchten Zieldomäne möglichst ähnlich sind. Aus den ähnlichsten Quellen wird eine bestimmte Anzahl der Quellen zur Adaption ausgewählt, wobei das Zusammenspiel der Verteilungen der Daten aus den ausgewählten Quelldomänen berücksichtigt wird. Die Trainingsbeispiele der ausgewählten Quellen werden entsprechend ihrem Ähnlichkeitsmaß gewichtet und zur semi-überwachten DA verwendet.

Die Methode wurde in vier unterschiedlichen anspruchsvollen Szenarios aus der Fernerkundung getestet, und es zeigte sich, dass ein kleiner positiver Transfer über den gesamten Datensatz mit der Quellenselektionsmethode erreicht werden kann. Das Potential des Ähnlichkeitsmaßes wurde in [Vogt et al., 2018] allerdings nicht zur Prädiktion von NT ausgetestet. Außerdem wird im Rahmen dieser Arbeit nur eine Quelldomäne für die DA vorausgesetzt. Ein solcher Ansatz zur Messung der Ähnlichkeit zwischen den Domänen auf Basis der zugehörigen Randverteilungen der Daten kann für die Prädiktion von NT, insbesondere für semi-überwachte und unüberwachte DA, durchaus von Interesse sein. Allerdings können mit einem herkömmlichen Ähnlichkeitsmaß auf Basis der MMD nur die Unterschiede zwischen den Randverteilungen der Daten aus der Quell- und Zieldomäne berücksichtigt werden.

Bruzzone und Marconcini [2010] verzichten auf eine empirische Messung der Ähnlichkeit zwischen der Quell- und Zieldomäne und schlagen eine heuristische Strategie zur zirkulären Validierung (en: *circular validation strategy: CVS*) vor. Dabei wird zunächst der an der Quelldomäne angelegte Klassifikator in dem DA-Prozess an die Verteilung der Daten in der Zieldomäne angepasst und zur Klassifikation der Zieldaten verwendet. Anschließend werden die Rollen getauscht und die DA findet in umgekehrter Richtung statt, wobei der Klassifikator dieses Mal an den semi-gelabelten Daten aus der Zieldomäne angelehrt wird und an die Verteilung der Daten in der Quelldomäne angepasst wird. Die Idee dahinter ist, dass Fälle von NT identifiziert werden können, indem die Klassifikationsgenauigkeit des resultierenden Klassifikators in der Quelldomäne gemessen wird, in der die gelabelten Daten verfügbar sind. Dabei kann die Genauigkeit des Klassifikators als ein Maß für die Ähnlichkeit interpretiert werden. Man wendet schließlich einen Schwellwert auf die Klassifikationsgenauigkeit nach der inversen DA an, um Fälle von NT vorherzusagen und auszuschließen. Ein Vorteil der CVS ist, dass sie nur Labels in der Quelldomäne erfordert. Es wird in den Experimenten gezeigt, dass die Methode den NT bis zu einem gewissen Grad vermeiden kann. Allerdings können auch die Fälle, die ursprünglich zu positivem Transfer geführt hätten, als NT ausgeschlossen werden, wenn z.B. nun der Transfer von der Ziel- zur Quelldomäne scheitert, der für die CVS nötig ist.

Ähnlich zu der Quellenselektion schlagen einige Autoren vor, geeignete Trainingsdaten aus mehreren vorhandenen Quelldomänen simultan auf die Zieldomäne zu übertragen. Auch hier wird von mehreren Quelldomänen ausgegangen, in denen gelabelte Daten vorliegen. Im Unterschied zur Quellenselektion wird hier das Vorhandensein einer ähnlichen Quelle nicht vorausgesetzt. Stattdessen wird nach Trainingsbeispielen gesucht, die ein Transfer auf die Zieldomäne hin unterstützen. Auf diese Weise wird versucht, den NT zu vermeiden, der beim Transfer unter Verwendung von Trainingsdaten aus einer einzigen und eventuell unähnlichen Quelle auftreten kann. Im Unterschied zu der üblichen DA wird hier die Ähnlichkeit der Verteilung der Trainingsbeispiele aus vorhandenen Quelldomänen zu der Verteilung der Daten in der Zieldomäne einbezogen. Die ausgewählten Trainingsbeispiele bilden dann sozusagen eine synthetische Quelle, deren Daten eine zu den Daten aus der Zieldomäne möglichst ähnliche Verteilung haben sollen. Yao und Doretto [2010] erweitern beispielsweise das Boosting-basierte TL-Framework von [Dai et al., 2007], um solche relevanten Trainingsbeispiele auszuwählen. Die Autoren schlagen eine iterative Methode vor, die jedoch eine gewisse Menge an gelabelten Daten aus der Zieldomäne

erfordert. In jeder Iteration wird zunächst ein schwacher Klassifikator für jedes Ziel-Quelle-Paar gefunden und dann wird daraus ein resultierender schwacher Klassifikator bestimmt, der die Fehlerrate der Klassifikation in der Zieldomäne minimiert. Anschließend folgt eine Umgewichtung der Trainingsbeispiele, wobei das Gewicht der Trainingsbeispiele aus der Quelldomäne, die in der aktuellen Iteration falsch klassifiziert wurden, reduziert und jenes der Trainingsbeispiele aus der Zieldomäne, die falsch klassifiziert wurden, vergrößert wird. Die Schritte werden bis zur Konvergenz wiederholt. Ein ähnlicher Ansatz wurde in [Eaton und desJardins, 2011] vorgeschlagen. Der wesentliche Unterschied besteht darin, dass vor dem Boosting alle Trainingsbeispiele aus den vorhandenen Quelldomänen und der Zieldomäne zu einem Trainingsdatensatz zusammengeführt werden. Auch Ge et al. [2014] gehen ähnlich vor, verwenden jedoch dafür einen Ansatz auf Basis eines Clustering-Algorithmus. Die Gewichtung der relevanten Trainingsbeispiele aus jeder Quelldomäne erfolgt hier somit clusterweise entsprechend der lokalen Ähnlichkeit der Quell- und Zieldomäne in dem jeweiligen Bereich im Merkmalsraum. Um die lokale Gewichte zu bestimmen, kommt der Spektrale Clustering-Algorithmus (en: *spectral clustering algorithm*) aus [Shi und Malik, 2000] zum Einsatz. Damit werden zunächst die Daten aus der Ziel- und der jeweiligen Quelldomäne separat geclustert, wobei jedem Cluster ein Label zugeordnet wird. Die Zuordnung der Labels zu den Clustern der Zieldomäne erfolgt durch Propagieren der vorhandenen Labels in der Zieldomäne auf das gesamte jeweilige Cluster. Anschließend werden durch Vergleich von korrekten und falschen Zuordnungen in den entsprechenden Clustern aus der Quell- und Zieldomäne die Gewichte für jeden Cluster der Quelldomänen ermittelt. Die Experimente wurden für Anwendungen aus der Medizin und der Spam-Filterung durchgeführt. Alle soeben diskutierten Methoden erfordern eine gewisse Menge an gelabelten Daten in der Zieldomäne, die im Rahmen dieser Arbeit nicht zur Verfügung stehen.

Ein anderer Ansatz, der von mehreren verfügbaren Quellen ausgeht, wird in [Seah et al., 2013] vorgestellt. Die Autoren gehen davon aus, dass die Ursache für NT auf ein Ungleichgewicht der Klassen (en: *class imbalance*) zwischen den Domänen zurückzuführen ist. Seah et al. [2013] stellen einen Ansatz namens *predictive distribution matching* (PDM) vor, der versucht, die bedingte Verteilung der Klassen und das Klassengleichgewicht der Daten aus der Quell- und Zieldomäne auf einander abzustimmen. Das wird erreicht, indem nur bestimmte Trainingsbeispiele aus den Quelldomänen im Adaptionprozess verwendet werden, während die restlichen Trainingsbeispiele aus dem Adaptionprozess ausgeschlossen werden. Die Auswahl solcher Trainingsbeispiele erfolgt nach einem auf Basis der a-posteriori Wahrscheinlichkeit definierten *Kriterium der positiven Transferierbarkeit*. Die nach dem Ausschluss verbleibenden Trainingsbeispiele werden zum Trainieren des Klassifikators für die Zieldomäne verwendet. Grundsätzlich sind hier keine gelabelten Daten in der Zieldomäne erforderlich. Das Framework wurde mit SVM und LR als Basisklassifikator auf Testdatensätzen zur Textklassifikation getestet. Im Rahmen der vorliegenden Arbeit wird jedoch jeweils nur eine Quelldomäne für die DA vorausgesetzt, was das Auffinden einer ausreichenden Menge an geeigneten Trainingsbeispielen erschweren kann. Außerdem werden in dieser Arbeit keine expliziten Annahmen über den Grund für einen NT gemacht.

3.2 Diskussion

Domänenadaption. In der Literatur findet sich eine Vielzahl von Ansätzen, die sich mit DA beschäftigen [Weiss et al., 2016]. Angesichts der Vielzahl von Einsatzmöglichkeiten und potentiellen Einsparungen wird der DA in der Fernerkundung viel Aufmerksamkeit geschenkt [Tuia et al., 2016]. Die meisten der in Kapitel 3.1 vorgestellten Ansätze zu DA aus der Fernerkundung sind auf bestimmte Szenarios, wie z.B. die Aktualisierung einer Landbedeckungskarte auf Basis von multitemporalen Aufnahmen eines Gebietes, spezialisiert [Bruzzone und Marconcini, 2010; Bahirat et al., 2012; Othman et al., 2016]. Dabei wird das Szenario, in dem die Adaption zwischen räumlich disjunkten Gebieten stattfindet, oft vernachlässigt. Neben den in beiden Szenarios auftretenden Unterschieden der Beleuchtung bzw. der Sensorcharakteristik können dabei auch solche in Hinblick auf die Struktur der Bodenbedeckung bzw. der Bebauung auftreten. In dieser Arbeit soll ein Ansatz zur Klassifikation von Luft- und Satellitenbildern entwickelt werden, der ein Wissenstransfer zwischen räumlich und/oder zeitlich disjunkten Gebieten erlaubt, wobei die Gebiete sich in Bezug auf veränderte Sensorcharakteristik, Lichtverhältnisse, saisonale Effekte, aber auch Bodenbedeckung unterscheiden dürfen. Somit unterscheiden sich die Daten der Quelldomäne (Trainingsdaten) von den Daten der Zieldomäne (zu klassifizierende Testdaten) aus der Sicht der Klassifikation in Bezug auf die Verteilung der Merkmalsrepräsentationen (Rand- bzw. bedingte Klassenverteilung). Ein verbreitetes Problem bei der Klassifikation von Fernerkundungsdaten liegt darin, dass die gelabelten Daten nur für die Quelldomäne aus einem früheren Projekt vorliegen, jedoch nicht für die zu klassifizierende Bilddaten aus der Zieldomäne. Auf dieses Problem wird im Rahmen der vorliegenden Arbeit eingegangen. Dies schließt Verfahren aus, die sich mit der Auswahl der invarianten Merkmale (Persello und Bruzzone [2016]), Adaption der Datenverteilungen (Tuia [2014]), Datenerweiterung ([Izquierdo-Verdiguier et al., 2013]) oder mit dem Instanzentransfer, wie TRADABOOST ([Dai et al., 2007]) oder IRHTL ([Li et al., 2017]), im Kontext der überwachten DA beschäftigen. Weiterhin können auch die Methoden der unüberwachten DA hier nicht zur Klassifikation angewendet werden, da keine Interaktion des Benutzers vorausgesetzt wird und kein a-Priori Wissen über die Verteilung der Merkmalsausprägungen der jeweiligen Klassen vorliegt. Aus dem selben Grund können hier auch die Methoden des Aktiven Lernens ([Tuia et al., 2011b]) nicht angewandt werden. Gegen die Methoden der DEEP DA spricht die Tatsache, dass Deep Learning Methoden im Allgemeinen sehr viele Trainingsdaten brauchen [Wang und Deng, 2018] (auch in der Quelldomäne im Rahmen der semi-überwachten DA), deren Anzahl in dieser Arbeit zu reduzieren ist.

Im Rahmen dieser Arbeit wird LR (siehe Kapitel 2.1.1) als Basisklassifikator eingesetzt. LR ist ein generativer probabilistischer Klassifikator mit geringerer Rechenkomplexität, der auf einfache Weise auf Mehrklassenprobleme erweitert werden kann. Die meisten zitierten Arbeiten zu der semi-überwachten DA mit dem Transfers von Instanzen integrieren GMM als Modell für die Verteilung der Daten zur Lösung des Problems [Bruzzone und Prieto, 2001; Rajan et al., 2006; Bahirat et al., 2012]. Im Gegensatz dazu erfordert die LR keine Annahmen über die Verteilung der Daten [Bishop, 2006]. Andere Arbeiten in diesem Kapitel setzen auf Kernmethoden auf, wie z.B. SVM [Bruzzone und Marconcini, 2010; Sun et al., 2013; Li et al., 2017]. SVM gilt als ein

komplexer und vergleichsweise langsamer Klassifikator [Abe, 2010]. Weiterhin ist die Standard-SVM zur Lösung von Zweiklassenproblemen konzipiert. Eine Erweiterung auf mehrere Klassen erfordert dabei spezielle Strategien zur Aufteilung des Klassifikationsproblems in mehrere binäre Klassifikatoren, wodurch die Komplexität und die Rechenzeit weiter steigen. Ein Ensemble von Entscheidungsbäumen wurde z.B. in [Rajan et al., 2006] zur Lösung des DA-Problems eingesetzt. Die Methode erfordert jedoch weitere Algorithmen, wie z.B. EM in [Rajan et al., 2006], zur Initialisierung und Anpassung der Parameter der Bäume, von denen das Ergebnis stark abhängig ist. Solche Algorithmen können selbst von der Verschiebung der Verteilungen betroffen sein. Für die Anwendung eines probabilistischen Klassifikators, wie LR, spricht außerdem, dass der probabilistische Output der LR einfach zu interpretieren ist. Dieser Vorteil kann beim iterativem Transfer von Instanzen zur Gewichtung der Trainingsdaten verwendet werden.

Der hier entwickelte iterative Ansatz zur DA auf Basis der LR wurde von Bruzzone und Marconcini [2010] inspiriert, welcher methodisch der vorliegenden Arbeit nahe steht. Im Gegensatz zu SVM aus [Bruzzone und Marconcini, 2010] weist LR eine geringere Rechenkomplexität auf und kann auf einfache Weise auf Mehrklassenprobleme angewandt werden. Aufgrund der unterschiedlichen Vorgehensweisen der Klassifikatoren müssen die Strategien zur Auswahl der auszutauschenden Trainingsbeispiele und der Prozess der Schätzung der aktuellen Parameter in jedem Iterationsschritt anders durchgeführt werden. Es ist außerdem festzuhalten, dass die DA auf Basis der LR nach bestem Wissen des Autors für die Klassifikation von Fernerkundungsdaten bisher kaum untersucht wurde. Die Ausnahme in der zitierten Literatur stellt die Arbeit von Zhang et al. [2010] und Seah et al. [2013]. Zhang et al. [2010] beschäftigen sich ebenso mit Transfer von Instanzen im Kontext der semi-überwachten Adaption und setzt LR als Basisklassifikator ein, wobei der Transfer ausgehend von mehreren Quelldomänen stattfindet. Diese Arbeit unterscheidet sich von [Zhang et al., 2010] auch darin, dass Zhang et al. [2010] nur von unterschiedlichen Randverteilungen zwischen den Domänen ausgehen. Außerdem verfolgen sie eine andere, nicht iterative Strategie zur Anpassung des Klassifikators, die Umgewichtung der Trainingsbeispiele aus allen Quelldomänen vorsieht, und diese Methode geht von sehr einfachen binären Problemen aus dem Bereich der Text Data Mining aus. Die Arbeit von Seah et al. [2013] geht ebenso davon aus, dass Trainingsdaten aus mehreren Quellen zur Verfügung stehen. Deren iterative Strategie zur Anpassung des Klassifikators basiert darauf, dass nur bestimmte Trainingsbeispiele aus den Quelldomänen zum Training des Klassifikators auf die Zieldomäne hin verwendet werden, während die restlichen davon ausgeschlossen bleiben. Diese Strategie unterscheidet sich somit von der iterativen Anpassungsstrategie in dieser Arbeit. Außerdem beschäftigen sich Autoren mit dem Ungleichgewicht der Klassen (*class imbalance*) als wesentliche Ursache für die Unterschiede zwischen den Domänen, während in dieser Arbeit keine solche Annahmen getroffen werden.

Prädiktion von negativem Transfer. Viele der in Kapitel 3.1.6 vorgestellten Ansätze zum Umgang mit NT bauen auf der Verfügbarkeit von mehreren gelabelten Quelldomänen auf [Yao und Doretto, 2010; Vogt et al., 2018]. Sie gehen dabei davon aus, dass es unter den vorhandenen Quellen bereits solche gibt, die selbst oder deren Trainingsbeispiele zu der jeweiligen Klassenverteilung der zu klassifizierenden Zieldomäne ähnlich genug sind. Im Rahmen der vorliegenden

Arbeit wird jedoch jeweils nur eine Quelldomäne für die DA vorausgesetzt, was das Auffinden einer ausreichenden Menge an geeigneten Trainingsbeispielen stark beeinträchtigt. Andere vorgestellte Ansätze zielen auf eine Vermeidungsstrategie, z.B. durch eine geschickte Auswahl von Trainingsdaten, die die beiden Domänen näher aneinander bringen sollen [Seah et al., 2013; Persello und Bruzzone, 2016]. Oft kommen dabei auch gelabelte Daten aus der Zieldomäne zum Einsatz [Shi und Malik, 2000; Ge et al., 2014]. Da das Ziel dieser Arbeit darin besteht, eine geeignete Strategie zur Prädiktion von NT für den Fall der semi-überwachten DA zu erarbeiten, können solche Ansätze nicht angewendet werden. Eine Strategie zur Prädiktion von NT, die keine Labels in der Zieldomäne voraussetzt, wurde in den zitierten Arbeiten nur von [Bruzzone und Marconcini, 2010] untersucht. Diese Methode kann NT bis zu einem gewissen Grad vermeiden, sie schließt jedoch auch Fälle aus, die ursprünglich zum positiven Transfer geführt hätten, da die dem Verfahren zugrunde liegende Heuristik nicht immer zutrifft. Es ist damit festzuhalten, dass die Prädiktion von NT für den Fall, in dem keine gelabelten Daten in der Zieldomäne vorliegen, noch nicht ausreichend untersucht wurde. Die Leistungsfähigkeit der DA wird oft in Verbindung mit der Ähnlichkeit der Domänen gebracht, wobei eine unzureichende Ähnlichkeit sich negativ auf die Übertragung vom Wissen auswirken kann [Rosenstein et al., 2005]. Es ist jedoch schwierig, ein aussagekräftiges Maß für die Ähnlichkeit zwischen der Quell- und Zieldomäne zu finden. In diesem Kontext können nichtparametrische Funktionen, wie MMD, Abhilfe schaffen. Die MMD liefert ein generisches Maß für die Ähnlichkeit zweier Verteilungen und kommt völlig ohne Labels aus. Die MMD wurde z.B. in [Vogt et al., 2018] in Kontext der Vermeidung von NT eingesetzt. Die hier entwickelte Strategie zur Prädiktion von NT setzt auf MMD auf. Um die Aussagekraft der mmd-Metrik in Hinblick auf die Unterschiede der Verteilungen, vor allem auch jene der bedingten Verteilungen der Klassen bei gegebenen Daten, zu erweitern, wird hier vorgeschlagen, die Klassenlabels aus der Quelldomäne in die Berechnung der Distanzmetrik einzubeziehen. Nach bestem Wissen des Autors wurde das in der Literatur bisher nicht untersucht.

4 Methodik

Dieses Kapitel stellt den Kern der Arbeit dar und beschreibt den entwickelten Ansatz für die Domänenadaption zur Klassifikation von Luftbildern. Das Kapitel 4.1 gibt einen allgemeinen Überblick über den Ansatz und das Konzept der iterativen Anpassung. Die für die Domänenadaption methodisch relevanten Aspekte in Bezug auf den Basisklassifikator werden in Kapitel 4.2 beschrieben. Das Kapitel 4.3 beschäftigt sich mit dem iterativen Algorithmus zur Anpassung des Klassifikators im Prozess der Domänenadaption, während Kapitel 4.4 ein Ansatz zur Erkennung und Vermeidung von negativem Transfer beschreibt. Abschließend findet im Kapitel 4.5 eine Diskussion des Ansatzes statt.

4.1 Konzept der iterativen Anpassung

Der Ansatz zur DA in dieser Arbeit dient dem Zweck der Klassifikation von Luftbildern. Bei der DA geht man von zwei Domänen aus: einer Quelldomäne, in der eine relativ große Menge an Trainingsdaten aus früheren Projekten vorhanden ist, und einer Zieldomäne mit neuen zu klassifizierenden Testdaten, in der nur wenige oder gar keine Trainingsdaten zur Verfügung stehen. Im Rahmen dieser Arbeit wird ein semi-überwachter DA-Ansatz verfolgt, der davon ausgeht, dass gelabelte Daten nur in der Quelldomäne vorliegen. Der Klassifikator wird also auf Bilddaten aus der Quelldomäne angelernet, für die gelabelte Trainingsdaten vorliegen, und auf die zu klassifizierende Szene aus der Zieldomäne übertragen, in der keine Labels zur Verfügung stehen. Bilddaten aus der Quell- und Zieldomäne können dabei untereinander räumlich und/oder zeitlich disjunkt sein, sich in Bezug auf Beleuchtungsverhältnisse und saisonale Effekte unterscheiden und den Gebieten angehören, die unterschiedliche Bebauungsstruktur und unterschiedlichen Grad der Urbanisierung aufweisen. Ziel der DA ist ein verbessertes Lernen in der Zieldomäne unter Verwendung vom Wissen aus der Quelldomäne. Der Klassifikator soll also mittels DA an die Verteilung der neuen Daten angepasst werden, wobei der Genauigkeitsverlust gegenüber einem anhand einer Trainingsstichprobe aus der Zieldomäne angelerten Klassifikator möglichst klein gehalten werden soll.

Die Quell- und Zieldomäne unterscheiden sich im Rahmen dieser Arbeit gemäß der Annahme aus Kapitel 2.2.2 durch die gemeinsame Verteilung der Merkmalsvektoren \mathbf{x} und der Klassenlabels y der Stichproben, d.h. $p(\mathbf{x}_S, y_S) \neq p(\mathbf{x}_T, y_T)$ [Tuia et al., 2016]. Wegen $p(\mathbf{x}, y) = p(y|\mathbf{x}) \cdot p(\mathbf{x})$ kann man das auf Unterschiede in $p(\mathbf{x}_S) \neq p(\mathbf{x}_T)$ und/oder $p(y_S|\mathbf{x}_S) \neq p(y_T|\mathbf{x}_T)$ aufspalten (siehe Abbildung 2.2). Das Konzept der iterativen Anpassung des Klassifikators geht dabei davon aus,

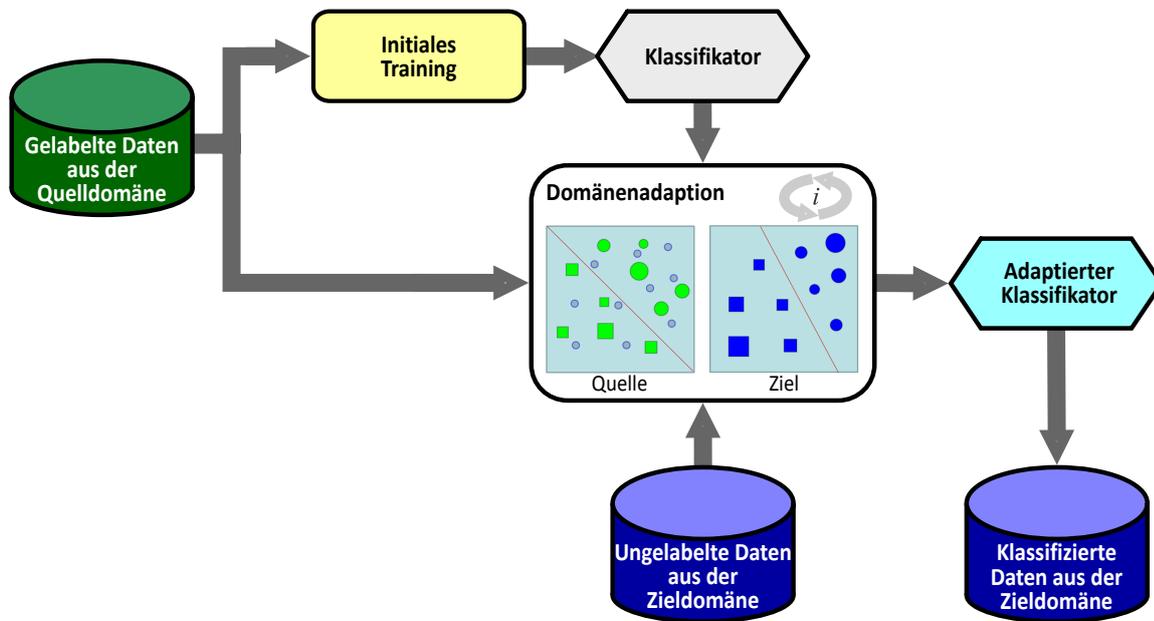


Abbildung 4.1: Ablaufdiagramm des vorgestellten DA-Verfahrens zum Transfer von Instanzen. Der initiale Klassifikator wird an dem Trainingsdatensatz angelernt (gelb), der zu Beginn nur gelabelte Trainingsbeispiele aus der Quelldomäne beinhaltet. Danach wird der Klassifikator durch sukzessive Veränderung des Trainingsdatensatzes an die Verteilung der Daten in der Zieldomäne angepasst (weiß). Dabei werden die Instanzen der Quelldomäne (grüne Kreise und Quadrate) schrittweise durch Instanzen der Zieldomäne im Trainingsdatensatz ausgetauscht. Beim Austausch erhalten die ungelabelten Instanzen der Zieldomäne (graue Kreise) ihre Semi-Labels (blaue Kreise und Quadrate) zugewiesen. Anschließend wird der Klassifikator in jeder Iteration auf dem aktuellen Trainingsdatensatz neu trainiert. Am Ende besteht der Trainingsdatensatz nur noch aus semi-gelabelten Trainingsbeispielen aus der Zieldomäne. Auf diese Weise erfolgt die iterative Anpassung des Klassifikators und somit der Entscheidungsgrenze (rote Linie) an die Verteilung der Daten aus der Zieldomäne. Der adaptierte Klassifikator (cyan) wird dann genutzt, um die Daten der Zieldomäne zu klassifizieren.

dass der Klassifikator sukzessive an die Verteilung der Daten in der Zieldomäne angepasst werden kann. Voraussetzung dabei ist, dass die Domänen die Ähnlichkeitsbedingung erfüllen. Ein Ablaufdiagramm aus Abbildung 4.1 stellt die groben Schritte des im Rahmen dieser Arbeit entwickelten iterativen Ansatzes zur Klassifikation von Luftbildern mittels DA dar. Der DA-Ansatz besteht aus drei Hauptkomponenten: dem initialen Training des Basisklassifikators anhand von Daten aus der Quelldomäne, der inkrementellen DA und der anschließenden Klassifikation der Daten aus der Zieldomäne. Der entwickelte Ansatz zur Prädiktion von NT ist von dem Ablauf der DA unabhängig und wird deswegen in Kapitel 4.4 separat betrachtet.

Der vorliegende DA-Ansatz (siehe Abbildung 4.1) wurde für Bilddaten entwickelt. Die einzelnen Spektralinformationen können dabei direkt als Pixelmerkmale dienen oder zur Berechnung von sekundären Merkmalen für jedes Pixel eingesetzt werden (siehe Kapitel 5). Die primären und sekundären Merkmale spannen den Merkmalsraum für den entwickelten Ansatz auf, der identisch für die Quell- und Zieldomäne ist. Die gelabelten Trainingsdaten aus der Quelldomäne bilden den Ausgangspunkt für den folgenden Wissenstransfer mit Hilfe der DA. Als Basisklassifikator wird hier die bereits in Kapitel 2.1.1 beschriebene LR eingesetzt, die zu DA-Zwecken

speziell modifiziert wurde. Der Basisklassifikator wird zunächst anhand von Trainingsdaten aus der Quelldomäne angelernt. Danach findet die eigentliche Adaption mit dem Transfer von Instanzen statt. Ausgehend vom initialen Trainingsdatensatz werden die gelabelten Trainingsbeispiele aus der Quelldomäne sukzessive gelöscht und durch semi-gelabelte Trainingsbeispiele aus der Zieldomäne ersetzt. Dadurch entsteht ein hybrider Trainingsdatensatz auf Basis der Trainingsbeispiele aus beiden Domänen. In jedem Schritt wird der Klassifikator verändert, indem er basierend auf dem aktuellen Trainingsdatensatz neu trainiert wird. Dabei erfolgt eine sukzessive Verschiebung der Entscheidungsgrenzen und somit die Anpassung des Klassifikators an die neue Verteilung der Daten. Der Erfolg der Adaption hängt dabei wesentlich von der Auswahl der Trainingsbeispiele für den hybriden Trainingsdatensatz ab. Am Ende besteht der Trainingsdatensatz nur aus den semi-gelabelten Trainingsbeispielen aus der Zieldomäne. Der daraus resultierende angepasste Klassifikator wird zur Klassifikation der Bilddaten aus der Zieldomäne genutzt.

Der hier entwickelte iterative Algorithmus ist von der Vorgehensweise von [Bruzzone und Marconcini, 2010] inspiriert, zielt jedoch auf ein anderes Optimierungsproblem ab und verwendet dabei andere Methoden und Strategien. Im Gegensatz zu SVM aus [Bruzzone und Marconcini, 2010] wird hier LR als Basisklassifikator eingesetzt. Die LR weist eine geringere Rechenkomplexität auf, sie kann unmittelbar auf Mehrklassenprobleme angewandt werden und liefert dabei direkt einen probabilistischen Output. Aufgrund der unterschiedlichen Vorgehensweisen der Klassifikatoren müssen die Strategien zur Auswahl der auszutauschenden Trainingsbeispiele und der Prozess der Schätzung der aktuellen Parameter in jedem Iterationsschritt anders durchgeführt werden. Die genaue Vorgehensweise bei der Adaption wird in den nächsten Kapiteln beschrieben.

4.2 Basisklassifikator: Logistische Regression

Das DA-Verfahren mit dem Transfer von Instanzen soll möglichst unempfindlich gegenüber abrupten Veränderungen der Entscheidungsgrenze während der Adaption sein, um eine kontinuierliche Anpassung des Klassifikators zu ermöglichen. Dies wird im Rahmen dieser Arbeit einerseits durch die Modifikation des Basisklassifikators und andererseits durch die Strategien zur Auswahl der auszutauschenden Trainingsbeispiele umgesetzt. Die LR, die in dieser Arbeit als Basisklassifikator eingesetzt wird, wurde dabei speziell für die Zwecke der DA modifiziert. Die Grundlagen der LR wurden bereits in Kapitel 2.1.1 vorgestellt. Die einzelnen Modifikationen stellen eine Erweiterung dieses Verfahrens zur Klassifikation dar und betreffen die Einführung von Gewichten in den Trainingsprozess sowie eine verbesserte Regularisierung zur Vermeidung einer abrupten Veränderung der Parameter des Klassifikators und somit der Entscheidungsgrenze.

4.2.1 Gewichtung der Trainingsbeispiele

Jedes Trainingsbeispiel in dem aktuellen Trainingsdatensatz übt bei der LR eine gewisse Wirkung auf die Lage der Entscheidungsgrenze aus. Die Idee hinter der Gewichtung der Trainingsbeispiele besteht darin, diese Wirkung durch einen Parameter justieren zu können.

Die im Rahmen dieser Arbeit vorgeschlagenen Gewichte werden bei der Berechnung der Likelihood $p(\overline{TD}_h|\mathbf{w})$ aus Gleichung 2.7 berücksichtigt:

$$p(\mathbf{w}|\overline{TD}_h) \propto p(\mathbf{w}) \cdot \prod_{n=1}^N \prod_{\kappa=1}^K p(y_n = C^\kappa | \mathbf{x}_n, \mathbf{w})^{g_n \cdot t_{n\kappa}}. \quad (4.1)$$

Dabei steht der Term $g_n \in \mathbb{R}^+$ für ein Gewicht des n -ten Trainingsbeispiels aus dem aktuellen hybriden Trainingsdatensatz \overline{TD}_h . Der Term $p(y_n = C^\kappa | \mathbf{x}_n, \mathbf{w})$ bezeichnet die a-posteriori Wahrscheinlichkeit auf Basis der Softmax-Funktion aus Gleichung 2.3. Dabei werden in der Softmax-Funktion statt den ursprünglichen Merkmalsvektoren \mathbf{x}_n transformierte Merkmalsvektoren $\Phi(\mathbf{x}_n)$ gemäß der Beschreibung aus Kapitel 2.1.1 verwendet, um nicht linear separierbare Klassen trennen zu können. Der Term $t_{n\kappa}$ in Gleichung 4.1 ist eine Indikatorvariable, die den Wert 1 annimmt, wenn das Klassenlabel y_n des Trainingsbeispiels n aus \overline{TD}_h das Label C^κ aufweist und sonst null ist. Schließlich beschreibt der Faktor $p(\mathbf{w})$ ein a-priori Wissen über die Verteilung der Modellparameter und wird zur Regularisierung verwendet.

Aus der Gleichung 4.1 ergibt sich für die zu minimierende Kostenfunktion $E(\mathbf{w})$ der folgende Ausdruck:

$$E(\mathbf{w}) = -\ln(p(\mathbf{w}|\overline{TD}_h)) = -\left(\sum_{n=1}^N \sum_{\kappa=1}^K g_n \cdot t_{n\kappa} \cdot \ln(y_{n\kappa}) + \ln(p(\mathbf{w}))\right), \quad (4.2)$$

wobei $y_{n\kappa}$ der a-posteriori Wahrscheinlichkeit $y_{n\kappa} = p(y_n = C^\kappa | \mathbf{x}_n, \mathbf{w})$ entspricht. Der Parametervektor \mathbf{w} für die LR wird durch Minimierung der Kostenfunktion $E(\mathbf{w})$ aus Gleichung 4.2 bestimmt. Die Konkavität der Kostenfunktion $E(\mathbf{w})$ bleibt bei der Multiplikation jedes Summanden mit einer positiven reellen Zahl g_n erhalten. Somit besitzt diese Funktion ein einziges Minimum, das mit Hilfe des Newton-Raphson-Verfahrens bestimmt werden kann (siehe Kapitel 2.1.1).

Die Bestimmung des Parametervektors \mathbf{w} für die LR mit dem Verfahren nach Newton-Raphson gemäß Gleichung 2.9 erfolgt iterativ und erfordert die Berechnung des Gradienten $\nabla E(\mathbf{w})$ und der Hesse-Matrix \mathbf{H} der Kostenfunktion $E(\mathbf{w})$. Dabei wird der Regularisierungsterm $p(\mathbf{w})$ aus der Kostenfunktion in Gleichung 4.2 im nächsten Abschnitt detailliert betrachtet und wird hier deswegen nicht näher spezifiziert. Der Gradient $\nabla E(\mathbf{w})$ besteht aus partiellen Ableitungen von $E(\mathbf{w})$ aus Gleichung 4.2 nach dem jeweiligen Parametervektor \mathbf{w}_κ der Klasse C^κ , wobei $\kappa \in [2, \dots, K]$, d.h. $\nabla E(\mathbf{w}) = [\nabla_{\mathbf{w}_2} E(\mathbf{w})^T, \dots, \nabla_{\mathbf{w}_K} E(\mathbf{w})^T]^T$, mit:

$$\nabla_{\mathbf{w}_\kappa} E(\mathbf{w}) = \sum_{n=1}^N g_n \cdot (y_{n\kappa} - t_{n\kappa}) \cdot \Phi(\mathbf{x}_n) + \nabla_{\mathbf{w}_\kappa} \ln(p(\mathbf{w})). \quad (4.3)$$

Die Hesse-Matrix \mathbf{H} besteht aus $(K-1) \times (K-1)$ Blöcken $\mathbf{H}_{j\kappa}$ der Größe $M \times M$, wobei K die Anzahl der Klassen und M die Dimension der transformierten Merkmalsvektoren $\Phi(\mathbf{x}_n)$ ist. Jeder Block der Hesse-Matrix wird aus der zweiten partiellen Ableitungen von $E(\mathbf{w})$ nach \mathbf{w}_κ

und \mathbf{w}_j gebildet, die wie folgt definiert sind:

$$\mathbf{H}_{j\kappa} = \nabla_{\mathbf{w}_j} \nabla_{\mathbf{w}_\kappa} E(\mathbf{w}) = - \sum_{n=1}^N (g_n \cdot y_{nj} \cdot (I_{j\kappa} - y_{n\kappa}) \cdot \Phi(\mathbf{x}_n) \cdot \Phi(\mathbf{x}_n)^T) + \nabla_{\mathbf{w}_j} \nabla_{\mathbf{w}_\kappa} \ln(p(\mathbf{w})), \quad (4.4)$$

wobei \mathbf{I} die Einheitsmatrix ist, die aus einzelnen Elementen $I_{j\kappa}$ besteht.

Die Gewichte aus Gleichung 4.1 drücken das Vertrauen in die Korrektheit des Klassenlabels eines Trainingsbeispiels aus. Der Einsatz der Gewichte an dieser Stelle kann auf intuitive Weise als Indikator für mehrere Instanzen des gleichen Trainingsbeispiels interpretiert werden. Je größer das Gewicht eines Trainingsbeispiels ist, desto größer ist der Einfluss dieses Trainingsbeispiels auf die Position der Entscheidungsgrenze. Wird dagegen das Gewicht $g_n = 1$ für alle Instanzen des Trainingsdatensatzes verwendet, entspricht die beim Training zu minimierende Kostenfunktion aus Gleichung 4.2 der ursprünglichen Kostenfunktion aus Gleichung 2.8. Dies ist z.B. beim initialen Training auf den Daten aus der Quelldomäne der Fall. Mit dem Modell aus Gleichung 4.1 lassen sich die Gewichte je nach Kontext anpassen: für einzelne Trainingsbeispiele, für einzelne Klassen oder für ganze Domänen. Die genaue Vorgehensweise bei der Definition der individuellen Gewichte in dieser Arbeit wird in Kapitel 4.3.3 vorgestellt.

4.2.2 Regularisierung

Das Problem der Überanpassung wurde bereits in Kapitel 2.1.1 in Bezug auf die LR beschrieben. Bei der Überanpassung wird der Klassifikator an die Verteilung der Trainingsdaten so gut angepasst, dass seine Generalisierungseigenschaft gegenüber den Testdaten beeinträchtigt wird. Um eine Überanpassung zu vermeiden, kommt ein Regularisierungsterm bei der Minimierung der Kostenfunktion zum Einsatz. In dieser Arbeit wird die Gauß- oder L2-Regularisierung gemäß Gleichung 2.8 für das initiale Training auf den Daten aus der Quelldomäne verwendet. Dabei ist quadratische Regularisierungsfunktion stetig und lässt sich zur Berechnung des Gradienten und der Hesse-Matrix der Kostenfunktion $E(\mathbf{w})$ aus dem vorherigen Abschnitt auf einfache Weise differenzieren; die entsprechenden Terme wurden bereits in Abschnitt 2.1.1 (Gleichung 2.10 und 2.11) eingeführt.

Um das mögliche Problem der plötzlichen, abrupten Änderung des Parametervektors \mathbf{w} während der DA zu vermeiden, findet hier eine Verallgemeinerung der Regularisierung statt. Anstelle eines generischen Terms auf Basis der Normalverteilung mit Erwartungswert 0 und Standardabweichung σ wird für den Parametervektor \mathbf{w} ein Gauß'scher a-priori-Term mit Erwartungswert $\bar{\mathbf{w}}$ und Standardabweichung $\bar{\sigma}$ verwendet:

$$p(\mathbf{w}) \propto \exp\left(-\frac{(\mathbf{w} - \bar{\mathbf{w}})^T \cdot (\mathbf{w} - \bar{\mathbf{w}})}{2 \cdot \bar{\sigma}^2}\right). \quad (4.5)$$

Daher resultiert für den Term $\ln(p(\mathbf{w}))$ folgende Gleichung:

$$\ln(p(\mathbf{w})) = -\frac{(\mathbf{w} - \bar{\mathbf{w}})^T \cdot (\mathbf{w} - \bar{\mathbf{w}})}{2 \cdot \bar{\sigma}^2} + const. \quad (4.6)$$

Damit ergibt sich für die Gleichung 4.2 folgende Kostenfunktion $E(\mathbf{w})$, die zu minimieren ist:

$$E(\mathbf{w}) = -\ln(p(\mathbf{w}|\overline{TD}_h)) = -\sum_{n=1}^N \sum_{\kappa=1}^K g_n \cdot t_{n\kappa} \cdot \ln(y_{n\kappa}) + \frac{(\mathbf{w} - \overline{\mathbf{w}})^T \cdot (\mathbf{w} - \overline{\mathbf{w}})}{2 \cdot \overline{\sigma}^2}. \quad (4.7)$$

Dabei wurde in der Gleichung 4.7 der konstante Term aus Gleichung 4.6 weggelassen, da er für die Minimierung irrelevant ist. Der Parameter $\overline{\sigma}$ in der Gleichung 4.2 steuert damit im Allgemeinen die Stärke der Bestrafung von Modellen, deren Parametervektor \mathbf{w} von dem erwarteten Modell mit $\overline{\mathbf{w}}$ abweicht: bei kleineren Werten von $\overline{\sigma}$ werden solche Modelle stärker bestraft und umgekehrt. Diese Erweiterung wird während des DA-Prozesses eingesetzt, um dem Verfahren eine zusätzliche Stabilität gegenüber abrupten Veränderungen der Entscheidungsgrenze zu verleihen. Für initiales Training gilt dabei $\overline{\mathbf{w}} = \mathbf{0}$. Die verwendete Modifikation der Regularisierung wurde von [Kuznetsova et al., 2015] inspiriert, wobei sie dort in einem anderen Kontext verwendet wurde.

Die Bestimmung der Parametervektoren \mathbf{w} für die LR erfolgt durch Minimierung der Kostenfunktion $E(\mathbf{w})$ aus Gleichung 4.7. Da die modifizierte Funktion weiterhin konkav bleibt, kann hier das Verfahren nach Newton-Raphson gemäß Gleichung 2.9 eingesetzt werden. Für den Gradienten $\nabla E(\mathbf{w})$ und die Hesse-Matrix \mathbf{H} der Kostenfunktion $E(\mathbf{w})$ aus Gleichungen 4.3 und 4.4 ergeben sich durch die vorgeschlagene Modifikation folgende Gleichungen:

$$\nabla_{\mathbf{w}_\kappa} E(\mathbf{w}) = \sum_{n=1}^N g_n \cdot (y_{n\kappa} - t_{n\kappa}) \cdot \Phi(\mathbf{x}_n) + \frac{1}{\overline{\sigma}^2} \cdot (\mathbf{w}_\kappa - \overline{\mathbf{w}}_\kappa) \quad (4.8)$$

und

$$\mathbf{H}_{j\kappa} = -\sum_{n=1}^N (g_n \cdot y_{nj} \cdot (I_{j\kappa} - y_{n\kappa}) \cdot \Phi(\mathbf{x}_n) \cdot \Phi(\mathbf{x}_n)^T) + \frac{\mathbb{1}[j = \kappa]}{\overline{\sigma}^2} \cdot \mathbf{I}, \quad (4.9)$$

wobei \mathbf{I} die Einheitsmatrix ist, die aus einzelnen Elementen $I_{j\kappa}$ besteht. Die Funktion $\mathbb{1}[\cdot]$ ist die Indikatorfunktion, die den Wert 1 liefert, sobald ihr Argument wahr ist, und sonst den Wert 0 hat. Das bedeutet, dass der letzte Term nur für die Blöcke auf der Hauptdiagonale der Hesse-Matrix ungleich null ist. Das iterative Schema nach Newton-Raphson aus der Gleichung 2.9 wird solange wiederholt, bis die Norm des Gradienten $\nabla E(\mathbf{w})$ numerisch gleich null ist.

4.3 Domänenadaptation

Einen methodischen Schwerpunkt dieser Arbeit stellt der Ansatz zur Anpassung des Klassifikators an die Verteilung der Daten in der Zieldomäne dar. In diesem Kapitel werden zunächst die Hauptschritte des Algorithmus beschrieben. Danach werden die Strategien zur Auswahl der auszutauschenden Trainingsbeispiele vorgestellt. Schließlich wird der Ansatz zur Modellierung der Gewichte im Anpassungsprozess ausführlich erörtert.

4.3.1 Ablauf der Domänenadaption

Es wird hier davon ausgegangen, dass ein Quellbild (S), für welches gelabelte Daten vorliegen, und ein ungelabeltes Zielbild (T), das zu klassifizieren ist, zur Verfügung stehen. Für jedes Pixel n des jeweiligen Bildes ist ein Vektor \mathbf{x}_n mit charakteristischen Merkmalen vorhanden. Aus diesen Daten werden dann Stichproben $\mathbf{x}_{S,l}$ bzw. $\mathbf{x}_{T,q}$ gezogen, wobei l und q die Laufindizes der Merkmalsvektoren aus der Menge der Stichproben der Quell- bzw. Zieldomäne sind. Die Größe der jeweiligen Stichprobenmenge, die zum Zwecke der Adaption aus der Quell- und Zieldomäne gezogen wird, wird mit N_S^0 bzw. N_T^0 bezeichnet. Es können dann nur diese Stichproben an dem initialen Training und der Anpassung des Klassifikators teilnehmen. Gemäß den Annahmen dieser Arbeit stehen für die Daten aus der Quelldomäne die Labels zur Verfügung. Folglich ist für jede Stichprobe l aus den Daten der Quelldomäne das entsprechende Klassenlabel $y_{S,l}$ vorhanden. Damit werden die Menge der gelabelten Trainingsdaten aus der Quelldomäne als $\overline{D}_S^0 = \{(\mathbf{x}_{S,l}, y_{S,l})\}_{l=1}^{N_S^0}$ und die Menge der ungelabelten Trainingsdaten aus der Zieldomäne als $\overline{D}_T^0 = \{(\mathbf{x}_{T,q})\}_{q=1}^{N_T^0}$ definiert.

Ein Trainingsbeispiel im Sinne der Gleichung 4.7 besteht jedoch aus einem Tripel (\mathbf{x}_n, y_n, g_n) mit einem Merkmalsvektor \mathbf{x}_n , seinem Klassenlabel y_n und einem zugehörigen individuellen Gewicht g_n . In jeder Iteration i des DA-Verfahrens wird der Parametervektor \mathbf{w} der LR anhand der Trainingsbeispiele aus einem Trainingsdatensatz bestimmt. Der Trainingsdatensatz ist allerdings nicht statisch: Zu Beginn besteht er nur aus Trainingsbeispielen aus der Quelldomäne, dann werden Trainingsbeispiele aus der Quelldomäne sukzessive durch Trainingsbeispiele aus der Zieldomäne ersetzt, sodass der Trainingsdatensatz am Ende nur Trainingsbeispiele aus der Zieldomäne enthält. Er wird hier als hybrider Trainingsdatensatz \overline{TD}_h bezeichnet, da er Trainingsbeispiele aus beiden Domänen beinhalten kann. Der hybride Trainingsdatensatz \overline{TD}_h^i , an dem der Klassifikator in einer Iteration i trainiert wird, ist wie folgt definiert: $\overline{TD}_h^i = \left\{ (\mathbf{x}_{\overline{TD}_h,n}, y_{\overline{TD}_h,n}, g_{\overline{TD}_h,n}) \right\}_{n=1}^{N_{\overline{TD}_h}^i}$, wobei $N_{\overline{TD}_h}^i$ die Größe des Trainingsdatensatzes in der Iteration i bezeichnet. Andererseits besteht \overline{TD}_h^i in einer Iteration i des DA-Verfahrens aus einer Menge $\overline{TD}_S^i = \{(\mathbf{x}_{S,l}, y_{S,l}, g_{S,l})\}_{l=1}^{N_S^i}$ von N_S^i Trainingsbeispielen aus der Quelldomäne und $\overline{TD}_T^i = \{(\mathbf{x}_{T,q}, \tilde{y}_{T,q}, g_{T,q})\}_{q=1}^{N_T^i}$ von N_T^i Trainingsbeispielen aus der Zieldomäne, wobei $N_S^i \leq N_S^0$ und $N_T^i \leq N_T^0$ mit $N_S^i + N_T^i = N_{\overline{TD}_h}^i$ gilt. Für die Stichproben $\mathbf{x}_{S,l}$ und $\mathbf{x}_{T,q}$ aus der Quell- bzw. Zieldomäne beschreiben $g_{S,l}$ und $g_{T,q}$ dabei die jeweiligen zugeteilten Gewichte, während die Bezeichnung $\tilde{y}_{T,q}$ für ein der Stichprobe $\mathbf{x}_{T,q}$ aus der Zieldomäne zugewiesenes Semi-Label steht. In jeder Iteration i des Verfahrens wird der LR-Klassifikator verändert, indem die Parameter \mathbf{w} der LR anhand der Trainingsbeispiele aus dem aktuellen Trainingsdatensatz \overline{TD}_h^i neu bestimmt werden. Dabei erfolgt eine sukzessive Veränderung der Entscheidungsgrenzen und somit die Anpassung des Klassifikators an die neue Verteilung der Daten. Die Steuerung des DA-Prozesses erfolgt hier in erster Linie durch Modifikation von \overline{TD}_S^i und \overline{TD}_T^i und somit durch Veränderung von \overline{TD}_h^i . Die Vorgehensweise des entwickelten Algorithmus zur Anpassung des Klassifikators mit dem Transfer von gewichteten Instanzen besteht aus vier Schritten, die im Folgenden näher beschrieben werden. Ein exemplarisches Beispiel für den Ablauf der DA ist in Abbildung 4.2 dargestellt.

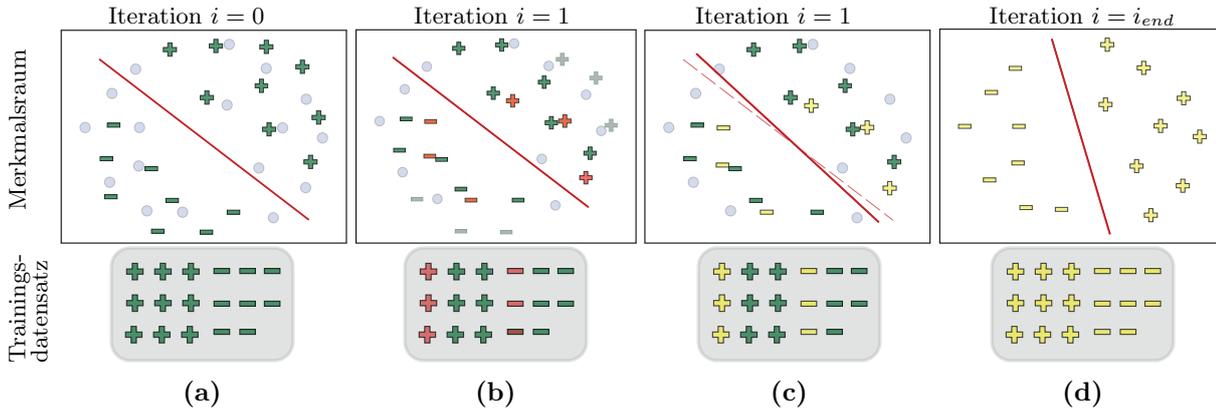


Abbildung 4.2: Beispiel für die DA mit Transfer von Instanzen. Die Abbildung zeigt exemplarisch den Vorgang bei der iterativen Anpassung des Klassifikators an einem Beispiel mit zwei Klassen im 2D-Merkmalraum (obere Reihe) und den jeweiligen zugehörigen hybriden Trainingsdatensatz (untere Reihe): (a) Training des initialen Klassifikators an gelabelten Daten aus der Quelldomäne; (b) Aktualisierung des Trainingsdatensatzes durch Auswahl der auszutauschenden Instanzen; (c) Anpassung des Klassifikators; (d) Resultierender Klassifikator. Legende: Plus- und Minuszeichen stehen für zwei Klassen; Grüne Zeichen markieren gelabelte Daten aus der Quelldomäne; Gelbe Zeichen markieren semi-gelabelte Daten aus der Zieldomäne; Graue Kreise stellen ungelabelte Daten aus der Zieldomäne dar; Graue Plus- und Minuszeichen sind zu eliminierende Instanzen aus der Quelldomäne; Rote Plus- und Minuszeichen sind aktuell hinzugefügte Instanzen der Zieldomäne; die rote durchgezogene Linie stellt die aktuelle Entscheidungsgrenze nach dem Training auf dem aktualisierten Satz von Trainingsdaten dar, während die gestrichelte Linie die Entscheidungsgrenze vor dem Training darstellt.

Schritt 1: Initialisierung.

Bei der Initialisierung erfolgt die Bestimmung des Parametervektors \mathbf{w}^0 des Ausgangsklassifikators ausschließlich anhand von Trainingsbeispielen aus der Quelldomäne. Daher wird in dieser Iteration 0 ($i = 0$) der Trainingsdatensatz \overline{TD}_h^0 mit allen für das Training ausgewählten Trainingsbeispielen aus der Quelldomäne initialisiert, während \overline{TD}_T^0 mit der leeren Menge initialisiert wird, weil noch keine Semi-Labels verfügbar sind. Es gilt also $\overline{TD}_h^0 = \overline{TD}_S^0$ und $\overline{TD}_T^0 = \emptyset$ mit $N_{\overline{TD}_h}^0 = N_S^0$. Die Gewichte für alle Trainingsbeispiele in der Kostenfunktion aus Gleichung 4.2 werden auf 1 gesetzt, also $g_{\overline{TD}_h, n}^0 = 1 \forall n$. Der Erwartungswert $\overline{\mathbf{w}}$ des Regularisierungsterms in der Gleichung 4.7 wird auf $\mathbf{0}$ gesetzt, da es noch kein Wissen über den Parametervektor \mathbf{w} aus einer früheren Iteration existiert: $\overline{\mathbf{w}}^0 = \mathbf{0}$. Der Parameter $\overline{\sigma}$ zur Steuerung der Regularisierung aus Gleichung 4.7 wird als Parameter auf einen vorgegebenen Wert σ_0 gesetzt, d.h. $\overline{\sigma}^0 = \sigma_0$. Das Ziel der Regularisierung liegt in diesem Fall in einer guten Generalisierung des Klassifikators auf ungesehene Daten, um die Ausgangslage für die Adaption zu verbessern. Es wird dabei angenommen, dass ein Ausgangsklassifikator mit guten Generalisierungseigenschaften größere Ähnlichkeit zu dem Klassifikator aufweisen würde, der an den gelabelten Trainingsdaten aus der Zieldomäne antrainiert wird.

Schritt 2: Aktualisierung des Trainingsdatensatzes.

Nach dem Training des Ausgangsklassifikators im Initialisierungsschritt wird in jeder weiteren Iteration i ($i \geq 1$) eine bestimmte Anzahl an Trainingsbeispielen aus der Menge \overline{TD}_S^{i-1} und

somit aus dem hybriden Trainingsdatensatz \overline{TD}_h^{i-1} entfernt. Dabei werden jedes Mal ρ_S Trainingsbeispiele pro Klasse C^κ , wobei $y_{S,l} = C^\kappa$ und $C^\kappa \in \mathcal{Y}$, die in \overline{TD}_S^{i-1} aktuell vorhanden sind, entfernt. Die gelöschten Trainingsbeispiele sind für das Training in den darauf folgenden Iterationen nicht mehr zugänglich. Analog dazu wird die Menge der Trainingsbeispiele \overline{TD}_T^{i-1} aus der Iteration $(i-1)$ für jede Klasse C^κ , wobei $\tilde{y}_{T,q} = C^\kappa$ und $C^\kappa \in \mathcal{Y}$, um ρ_T Trainingsbeispiele erweitert, was zu einer neuen erweiterten Menge \overline{TD}_T^i führt. Die Erweiterung erfolgt dabei durch Verschiebung der Trainingsbeispiele aus \overline{D}_T^0 unter Zuweisung der entsprechenden Semi-Labels und Gewichte, wobei die Gewichte in jeder Iteration in Abhängigkeit von der Lage der aktuellen Entscheidungsgrenze neu bestimmt werden. Damit besteht der aktuelle hybride Trainingsdatensatz in der Iteration i aus einer Mischung von N_S^i Trainingsbeispielen aus \overline{TD}_S^i und N_T^i Trainingsbeispielen aus \overline{TD}_T^i :

$$\begin{aligned} \overline{TD}_h^i &= \left\{ (\mathbf{x}_{\overline{TD}_h,n}, y_{\overline{TD}_h,n}, g_{\overline{TD}_h,n}) \right\}_{n=1}^{N_{\overline{TD}_h}^i} \\ &= \left\{ \{(\mathbf{x}_{S,l}, y_{S,l}, g_{S,l})\}_{l=1}^{N_S^i} \cup \{(\mathbf{x}_{T,q}, \tilde{y}_{T,q}, g_{T,q})\}_{q=1}^{N_T^i} \right\}, \end{aligned} \quad (4.10)$$

mit $N_S^i \leq N_S^{i-1}$ und $N_T^i \geq N_T^{i-1} \quad \forall i \geq 1$. Die Semi-Labels $\tilde{y}_{T,q}$ für alle Trainingsdaten $\mathbf{x}_{T,q}$ aus der Zieldomäne in dem Trainingsdatensatz werden dabei im Gegensatz zu den Klassenlabels der Quelldomäne automatisch auf Basis des aktuellen Klassifikators ermittelt bzw. aktualisiert. Dies ermöglicht den Trainingsbeispielen aus der Zieldomäne, ihre ursprünglich vorhergesagte Klasse in Abhängigkeit von der aktuellen Position der Entscheidungsgrenze zu ändern. Um jedoch eine abrupte Änderung der Parameter des Klassifikators zu vermeiden, wird eine solche Änderung des Semi-Labels durch Verringerung des Gewichts des betroffenen Trainingsbeispiels berücksichtigt, da die Veränderung auf eine steigende Unsicherheit des prädizierten Semi-Labels hindeutet. Eine detaillierte Beschreibung der Zuteilung der Semi-Labels findet in Kapitel 4.3.2 statt. Auf die erforderlichen Gewichte $g_{\overline{TD}_h,n}$ in dem aktuellen Trainingsdatensatz \overline{TD}_h^i , deren Vergabe und Anpassung wird in Kapitel 4.3.3 explizit eingegangen.

Schritt 3: Anpassung des Klassifikators.

Nach der Veränderung des hybriden Trainingsdatensatzes \overline{TD}_h^i im vorhergehenden Schritt erfolgt in jeder Iteration i ein erneutes Training der LR basierend auf dem aktuellen Satz von Trainingsbeispielen in \overline{TD}_h^i . Damit wird ein modifizierter Parametervektor \mathbf{w}^i der Entscheidungsfunktion ermittelt. Das bewirkt eine sukzessive Verschiebung der Entscheidungsgrenze zwischen den Trainingsbeispielen einzelner Klassen im Merkmalsraum und führt zu einer schrittweisen Anpassung des Klassifikators an die Verteilung der Daten aus der Zieldomäne.

Für die Regularisierung gemäß der Gleichung 4.7 liefert der Parametervektor \mathbf{w}^{i-1} aus der vorherigen Iteration $(i-1)$ bessere a-priori Information als das generische Modell mit $\overline{\mathbf{w}}^i = \mathbf{0}$, welches bei der Initialisierung im ersten Schritt verwendet wurde. Untersuchungen aus der Vorarbeit [Paul et al., 2015] zu der DA auf Basis der LR mit Transfer von Instanzen haben ergeben, dass plötzliche starke Änderungen des Parametervektors \mathbf{w} während der Adaption ein ernst zu nehmendes Problem darstellen. In [Paul et al., 2016] wurde gezeigt, dass mit Hilfe der Regularisierung auf Basis von Gleichung 4.7 solche abrupte Änderungen vermieden werden

können. Das Ziel dabei ist, starke Abweichung des Parametervektors \mathbf{w}^i in der aktuellen Iteration i von dem Parametervektor \mathbf{w}^{i-1} aus der vorherigen Iteration ($i-1$) zu vermeiden. Dafür wird der Parametervektor \mathbf{w}^{i-1} dem Erwartungswert $\bar{\mathbf{w}}^i$ beim Anlernen des Klassifikators in der nächsten Iteration i zugewiesen, d.h. $\bar{\mathbf{w}}^i = \mathbf{w}^{i-1}$. Der Parameter $\bar{\sigma}$ aus Gleichung 4.7 zur Steuerung der Regularisierung wird auf einen vordefinierten Wert σ_{DA} gesetzt, der während der gesamten Anpassung konstant bleibt, d.h. $\bar{\sigma}^i = \sigma_{DA} \forall i > 0$. Dieser Parameterwert σ_{DA} steuert somit die Stärke der Bestrafung von solchen Modellen, deren Parametervektor \mathbf{w}^i von dem erwarteten Modell mit $\bar{\mathbf{w}}^i = \mathbf{w}^{i-1}$ abweicht: bei kleineren Werten von σ_{DA} werden solche Modelle stärker bestraft und umgekehrt. Kleine Werte von σ_{DA} führen dabei zu einer langsameren Änderung der Entscheidungsgrenze als große.

Schritt 4: Konvergenz.

Der Endzustand im iterativen Ablauf der DA ($i = i_{end}$) wird erreicht, wenn der hybride Trainingsdatensatz \overline{TD}_h sich nicht mehr ändert. Für den Trainingsdatensatz bedeutet dies, dass keine Trainingsbeispiele aus dem Quelldatensatz in $\overline{TD}_h^{i_{end}}$ vorhanden sind und auch keine neuen Trainingsbeispiele aus dem Zieldatensatz zu $\overline{TD}_h^{i_{end}}$ hinzugefügt werden können (siehe Abschnitt zur Auswahl der Trainingsbeispiele aus der Zieldomäne in Kapitel 4.3.2), d.h. $\overline{TD}_S^{i_{end}} = \emptyset$ und $\overline{TD}_h^{i_{end}} = \overline{TD}_T^{i_{end}} = \{(\mathbf{x}_{T,q}, \tilde{y}_{T,q}, g_{T,q})\}_{q=1}^{N_T^{i_{end}}}$ mit $N_T^{i_{end}} \leq N_T$. Der endgültige Klassifikator wird somit nur auf Basis von Trainingsbeispielen aus dem Zieldatensatz mit Semi-Labels trainiert.

Nach der Konvergenz des Algorithmus zur iterativen Anpassung des Klassifikators liefert die LR den endgültigen Parametervektor $\mathbf{w}^{i_{end}}$, der daraufhin zur Klassifikation des gesamten Zielbildes angewendet wird.

4.3.2 Auswahl der Instanzen

Die LR wird in jeder Iteration aus einer aktuellen Menge an Trainingsbeispielen in \overline{TD}_h^i angelernt. Damit führt eine Modifikation des hybriden Trainingsdatensatzes zu einer Änderung des angelernten Parametervektors \mathbf{w} . Solche Modifikationen können schnell zu abrupten Veränderungen der Entscheidungsgrenze führen. Werden z.B. Instanzen der Quelldomäne, die (je nach verwendetem Klassifikator) einen größeren Einfluss auf die Änderung der Entscheidungsgrenze ausüben, aus \overline{TD}_h zu schnell oder an falschen Positionen im Merkmalsraum eliminiert, kann das zu einer starken, plötzlichen Verschiebung der Entscheidungsgrenze von ihrer aktuellen Position führen. Ein solche starke Verschiebung kann ihrerseits zu Inklusion von vielen Instanzen der Zieldomäne führen, deren Semi-Labels anhand des aktuellen Klassifikators und damit anhand der aktuellen Entscheidungsgrenze fehlerhaft sind, wodurch die DA zu einer suboptimalen Lösung konvergieren kann. Als Konsequenz würde das in einem NT resultieren. Die Strategien zur Veränderung des Trainingsdatensatzes sollen es dem Klassifikator erlauben, sich ausgehend von der Verteilung der Quelldaten an die Verteilung der Daten aus der Zieldomäne schrittweise anzupassen. Die Auswahl der auszutauschenden Trainingsbeispiele hat somit einen großen Einfluss auf die Qualität der DA und soll auf den Klassifikator und auf die Verteilung der Daten abgestimmt sein.

Einfluss der Trainingsbeispiele auf die Änderung der Entscheidungsgrenze. Bei den Strategien zur Auswahl der Instanzen wird zunächst der Einfluss der einzelnen Trainingsbeispiele auf die aktuelle Entscheidungsgrenze des Basisklassifikators näher betrachtet. Nachdem die Entscheidungsgrenze in einer Iteration des DA-Prozesses für den aktuellen Trainingsdatensatz optimiert wurde, übt jedes dem Trainingsdatensatz neu hinzugefügte bzw. entfernte Trainingsbeispiel einen gewissen Einfluss auf die Änderung deren Lage aus. Vor diesem Hintergrund wird hier die Änderung der Entscheidungsgrenze in Abhängigkeit von der Lage der Trainingsbeispiele analysiert, um die Strategien zur Auswahl der auszutauschenden Trainingsbeispiele auf den Klassifikator abzustimmen.

Betrachtet man die Gleichung 2.10 bzw. die Gleichung 4.8, so stellt man fest, dass der Gradient der Kostenfunktion $E(\mathbf{w})$ beim Training der LR von dem Term $(y_{n\kappa} - t_{n\kappa})$ abhängig ist. Damit hat jedes neue Trainingsbeispiel \mathbf{x}_n , das noch nicht gut klassifiziert wurde, einen höheren Einfluss auf die Änderung der Entscheidungsgrenze beim Training der LR auf dem aktualisierten Trainingsdatensatz. Da die a-posteriori Wahrscheinlichkeit $y_{n\kappa}$ mit der Distanz zur Entscheidungsgrenze steigt (folgt aus der Softmax-Funktion in Gleichung 2.3), wird die Änderung der Entscheidungsgrenze vor allem von Trainingsbeispielen in der Nähe der aktuellen Grenze beeinflusst. Daraus folgt: je näher ein neu hinzugefügtes Trainingsbeispiel an die Entscheidungsgrenze liegt, desto größeren Einfluss übt es auf deren Änderung aus und eine desto größere Verschiebung der Grenze wird es verursachen. Dies wird in der Abbildung 4.3 veranschaulicht.

Analog zu der oben gemachten Betrachtung führt auch das Entfernen eines Trainingsbeispiels \mathbf{x}_n aus dem aktuellen Trainingsdatensatz zu einer Änderung der Entscheidungsgrenze. Dabei gerät der optimierte Klassifikator und somit die Entscheidungsgrenze ins Ungleichgewicht. Die Änderung der Entscheidungsgrenze fällt umso stärker aus, je größer der Wert $(y_{n\kappa} - t_{n\kappa})$ des entfernten Trainingsbeispiels ausfällt, d.h. je näher er an der Entscheidungsgrenze lag. Diese Tatsachen werden im Weiteren bei den entwickelten Strategien berücksichtigt.

Abstand zur Entscheidungsgrenze. Eine geeignete Auswahl von auszutauschenden Trainingsbeispielen in Abhängigkeit von deren Einfluss auf die Entscheidungsgrenze erlaubt es dem Klassifikator, sich schrittweise an die Verteilung der Daten aus der Zieldomäne anzupassen. Da der Einfluss von Trainingsbeispielen auf die Änderung der Entscheidungsgrenze vom Abstand von der Entscheidungsgrenze abhängt, ist ein Ansatz zur Messung dieser Distanz notwendig. Das Ziel ist also, die Trainingsbeispiele $\mathbf{x}_{\overline{TD}_{h,n}}$ in Hinblick auf deren Entfernung zur aktuellen Entscheidungsgrenze B^i einordnen zu können. Die Bedingung dabei ist, dass die Distanz oder das Distanzmaß monoton mit dem Abstand von der Entscheidungsgrenze wächst.

Eine Distanz kann zum einen als euklidischer Abstand d_e im erweiterten Merkmalsraum $\Phi(\cdot)$ zwischen dem jeweiligen Trainingsbeispiel mit dem Merkmalsvektor $\Phi(\mathbf{x}_{\overline{TD}_{h,n}})$ und dem Punkt auf der aktuellen Entscheidungsgrenze B^i mit der kürzesten Entfernung zu diesem Merkmalsvektor gemessen werden. Allerdings muss dann bei der Berechnung die komplexe Abhängigkeit der resultierenden Entscheidungsgrenze von den einzelnen Hyperebenen, die eine Klasse von allen anderen Klassen im erweiterten Merkmalsraum $\Phi(\cdot)$ trennt, berücksichtigt werden. Um die Berechnung des euklidischen Abstandes zu vermeiden, wird stattdessen auf die a-posteriori

Wahrscheinlichkeit $p(y|\mathbf{x})$ gemäß Gleichung 2.3 als Abstandsmaß $d_{B^i}(\mathbf{x}_{\overline{TD}_h,n}) := p(y|\mathbf{x}_{\overline{TD}_h,n})$ zurückgegriffen. Sie steigt monoton mit der Distanz zur Entscheidungsgrenze und ist somit zum Ordnen von Stichproben auf Basis der Distanz geeignet. Zusätzlich folgt aus der Softmax-Funktion, dass solche Überlegungen sowohl für den Zweiklassen- als auch für den Mehrklassenfall gelten. Je größer $d_B(\cdot)$, desto weiter entfernt ist ein Trainingsbeispiel von der Entscheidungsgrenze und einen umso kleineren Einfluss hat dieses auf die Änderung der Parameter \mathbf{w}^i der aktuellen Entscheidungsgrenze B^i . Dabei gilt gemäß der Definition $d_B(\cdot) \in \mathbb{R}_0^+$. Damit sind die notwendigen Bedingungen an ein Distanzmaß vollständig erfüllt. Darauf basieren die im Rahmen dieser Arbeit entwickelten Kriterien zur Auswahl der auszutauschenden Trainingsbeispiele in den folgenden Abschnitten.

Auswahl der Trainingsbeispiele aus der Quelldomäne. Bei der Strategie für die Auswahl der auszutauschenden Trainingsbeispiele aus der Quelldomäne soll von deren Einfluss auf die Änderung der Entscheidungsgrenzen ausgegangen werden, um durch die Veränderung des Trainingsdatensatzes eine schrittweise Anpassung ohne abrupte Änderungen der Grenzen im DA-Prozess zu ermöglichen. Bei der Veränderung des Trainingsdatensatzes werden die Trainingsbeispiele aus der Quelldomäne in dem hybriden Trainingsdatensatz \overline{TD}_h sukzessive durch die Trainingsbeispiele aus der Zieldomäne ersetzt. Die Auswahl der zu eliminierenden Stichproben aus der Quelldomäne erfolgt auf Basis eines Kriteriums, welches über das Abstandsmaß $d_{B^i}(\cdot)$ mit der Distanz zur Entscheidungsgrenze zusammenhängt. Das Kriterium wird auf Basis der Bewertungsfunktion \mathcal{Q}_S definiert:

$$\mathcal{Q}_S(\mathbf{x}_{S,l}) = \begin{cases} d_{B^i}(\mathbf{x}_{S,l}) & \text{falls } y_{S,l} = \tilde{y}_{S,l}^{LR} \\ 2 - d_{B^i}(\mathbf{x}_{S,l}) & \text{falls } y_{S,l} \neq \tilde{y}_{S,l}^{LR} \end{cases}. \quad (4.11)$$

In Gleichung 4.11 ist $\tilde{y}_{S,l}^{LR}$ das durch den LR-Klassifikator in der vorherigen Iteration ($i - 1$) ermittelte Klassenlabel. Die Gleichung 4.11 kann mit Hilfe der Indikatorfunktion wie folgt umgeschrieben werden:

$$\mathcal{Q}_S(\mathbf{x}_{S,l}) = \mathbb{1}[y_{S,l} = \tilde{y}_{S,l}^{LR}] \cdot (2 \cdot d_{B^i}(\mathbf{x}_{S,l}) - 2) + 2 - d_{B^i}(\mathbf{x}_{S,l}). \quad (4.12)$$

Zur Umsetzung des Kriteriums auf Basis der Bewertungsfunktion \mathcal{Q}_S werden zunächst alle Trainingsbeispiele $\mathbf{x}_{S,l}$ aus der Quelldomäne \overline{TD}_S^{i-1} , die im hybriden Trainingsdatensatz \overline{TD}_h^{i-1} in der Iteration ($i - 1$) noch verblieben waren, pro Klasse $y_{S,l} = C^\kappa$ nach dem \mathcal{Q}_S -Wert absteigend sortiert. Dann werden die ρ_S Trainingsbeispiele pro Klasse mit den höchsten \mathcal{Q}_S -Werten aus der Menge \overline{TD}_S^{i-1} und somit aus \overline{TD}_h^{i-1} entfernt, um eine aktualisierte Menge \overline{TD}_S^i im hybriden Trainingsdatensatz zu erhalten. Wegen $0 \leq d_{B^i}(\mathbf{x}) \leq 1$ führt diese Formulierung dazu, dass Trainingsbeispiele aus der Quelldomäne, die auf der falschen Seite der Entscheidungsgrenze liegen (Trainingsbeispiele mit $y_{S,l} \neq \tilde{y}_{S,l}^{LR}$) bevorzugt eliminiert werden. Erst danach werden die Trainingsbeispiele entfernt, die auf der richtigen Seite der Entscheidungsgrenze liegen (Trainingsbeispiele mit $y_{S,l} = \tilde{y}_{S,l}^{LR}$). In den beiden Fällen wird mit den am weitesten von der Entscheidungsgrenze entfernten Trainingsbeispielen begonnen. Die Strategie zur Auswahl der Auswahl der Trainingsbeispiele aus der Quelldomäne ist in Abbildung 4.4 vereinfacht

dargestellt. Der Grundgedanke hinter dieser Strategie liegt darin, dass nach der vorrangigen Eliminierung von Trainingsfehlern ($y_{S,l} \neq \tilde{y}_{S,l}^{LR}$) die einflussreichsten Trainingsbeispiele, die in der Nähe der Entscheidungsgrenze liegen, erst ausgetauscht werden, nachdem die Clusterzentren der Merkmalsverteilungen einzelner Klassen aus der Zieldomäne stabil aufgebaut wurden. Dadurch werden kritische abrupte Änderungen des Klassifikators durch frühzeitige Eliminierung von Trainingsbeispielen in der Nähe der Entscheidungsgrenze vermieden.

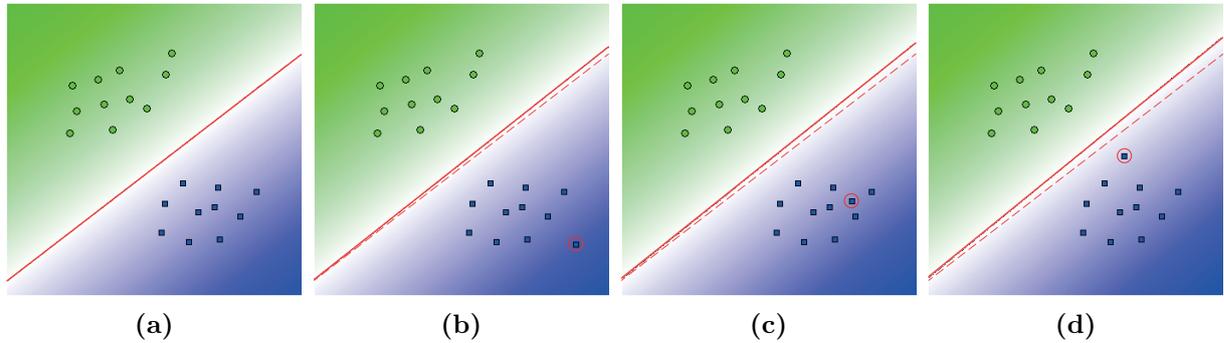


Abbildung 4.3: Einfluss eines neu hinzugefügten Trainingsbeispiels auf Änderung der Entscheidungsgrenze an drei realen Beispielen für unterschiedliche Lagen einer Trainingsinstanz als Funktion von dem Abstand zur Entscheidungsgrenze im 2D-Merkmalraum. Bild (a) zeigt die Ausgangslage des angelernten LR-Klassifikators und Bilder (b) - (d) zeigen die Änderung der Entscheidungsgrenze (rote durchgezogene Linie) in Relation zu der ursprünglichen Entscheidungsgrenze im Bild (a) (rote gestrichelte Linie). Neu hinzugefügte Instanzen sind durch rote Kreise markiert.

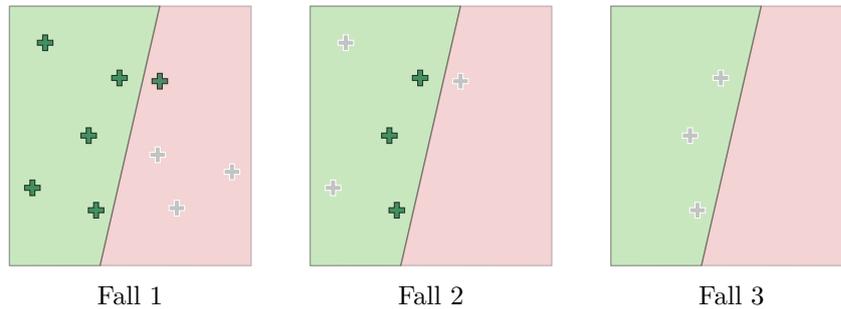


Abbildung 4.4: Drei vereinfachte Beispiele zur Veranschaulichung der Strategie zur Auswahl der zu eliminierenden Trainingsbeispiele aus der Quelldomäne auf Basis des Kriteriums aus Gleichung 4.12 für $\rho_S = 3$. Damit werden in jeder Iteration 3 Trainingsbeispiele aus der Quelldomäne im aktuellen Trainingsdatensatz eliminiert. Jeder Fall zeigt ein Zweiklassenproblem im Rahmen der DA in einem 2D-Merkmalraum, welcher beim Training auf einem Trainingsdatensatz durch die Entscheidungsfunktion in zwei den Klassen zugeordnete Bereiche aufgeteilt wurde, die durch die Farben Grün bzw. Rot markiert sind. Zur Vereinfachung werden nur die Trainingsbeispiele aus der Quelldomäne und nur für eine der Klassen, also Pluszeichen, gezeigt. Dabei entsprechen die Trainingsbeispiele, die im roten Bereich liegen, Trainingsfehlern ($y_{S,l} \neq \tilde{y}_{S,l}^{LR}$). Die anhand des Kriteriums in dem jeweiligen Fall zu eliminierenden Trainingsbeispiele sind grau markiert. Mit der Strategie werden zunächst die Trainingsbeispiele entfernt, die auf der falschen Seite der Entscheidungsgrenze liegen. Danach werden die Trainingsbeispiele auf der richtigen Seite entfernt, wobei in beiden Fällen mit den am weitesten von der Entscheidungsgrenze liegenden Instanzen begonnen wird.

Auswahl der Trainingsbeispiele aus der Zieldomäne. Bei der Auswahl der Trainingsbeispiele aus der Zieldomäne hat sich in der Untersuchung aus [Paul et al., 2015] im Rahmen dieser Arbeit ergeben, dass die Lage der ausgewählten Instanzen im Merkmalsraum in Bezug zu der aktuellen Verteilung der Daten im Trainingsdatensatz und zu der Entscheidungsgrenze von entscheidender Bedeutung für die Qualität der Adaption ist. Trainingsbeispiele, die nahe an der Entscheidungsgrenze liegen, bringen durch die auf Basis des aktuellen Klassifikators zugeteilten Semi-Labels mehr Unsicherheit in den DA-Prozess ein als solche, die weiter von der Entscheidungsgrenze entfernt liegen. Der Grund dafür liegt in den Semi-Labels solcher Trainingsbeispiele, die aufgrund der Unterschiede zwischen den Verteilungen der Daten aus der Quell- und Zieldomäne unsicher sind. Bei den Experimenten mit realen Datensätzen haben sich dabei die Fälle mit starken Überlappungen der Verteilungen der Daten unterschiedlicher Klassen als besonders schwierig für die Adaption erwiesen [Paul et al., 2015], in denen die Unsicherheit der Semi-Labels besonders hoch war. Andererseits üben die Trainingsbeispiele, die weit von der Entscheidungsgrenze liegen, weniger Einfluss auf die Änderung der Entscheidungsgrenze aus. Es wird hier unter der Annahme, dass die Verteilungen der entsprechenden Klassen aus der Quell- und Zieldomäne größere Überschneidung wegen der Ähnlichkeitsbedingung aufweisen, das Ziel verfolgt, als erstes die Trainingsbeispiele aus den Bereichen der größten Instanzendichte (nahe an den Clusterzentren) im Merkmalsraum in den Trainingsdatensatz zu verschieben. Solche Bereiche im Merkmalsraum sind in Bezug auf die zu den jeweiligen Merkmalsausprägungen zugewiesenen Semi-Labels sicherer als Stichproben, die z.B. nah an die Entscheidungsgrenze liegen, und können zugleich die aktuelle Entscheidungsgrenze besser unterstützen. Damit wird die Wahrscheinlichkeit für eine starke Änderung der Entscheidungsgrenze zu Beginn der Adaption reduziert, welche die DA zu einer suboptimalen Lösung führen kann. Erst nachdem die neuen Clusterzentren aufgebaut sind, sollen die restlichen Stichproben hinzugefügt werden, die die Lage der Grenze in Abhängigkeit von der Verteilung der Daten stärker justieren.

Um das anvisierte Ziel zu erreichen, sollen in jeder Iteration die am besten geeigneten Instanzen transferiert werden. Es wird daher jedes Trainingsbeispiel in \overline{TD}_T^{i-1} (für $i > 0$) in der aktuellen Iteration i als potentieller Kandidat betrachtet. Bei der Auswahl der Trainingsbeispiele aus der Zieldomäne wird die Entfernung zu anderen Trainingsbeispielen in dem hybriden Trainingsdatensatz berücksichtigt. Da die Klassifikation im erweiterten Merkmalsraum $\Phi(\cdot)$ stattfindet, soll auch die Entfernung dort analysiert werden. Zu diesem Zweck werden für jeden neuen Kandidaten für die Inklusion aus der Zieldomäne seine k -nächsten-Nachbarn (kurz: k -NN) in dem erweiterten Merkmalsraum $\Phi(\cdot)$ unter den Trainingsbeispielen aus dem hybriden Trainingsdatensatz \overline{TD}_h^{i-1} ermittelt. Für eine effiziente Suche nach den NN wird ein KD -Baum [Bentley, 1975] angewandt. Nachdem die Nachbarn bestimmt sind, wird der mittlere euklidische Abstand \bar{d}_{k-NN} des Kandidaten von seinen k nächsten Nachbarn ermittelt. Das Kriterium zur Auswahl der Trainingsbeispiele wird dann mit Hilfe des für jeden Trainingsbeispiel ermittelten Abstandes \bar{d}_{k-NN} wie folgt definiert:

$$Q_T(\mathbf{x}_{T,q}) = \bar{d}_{k-NN} + \mathbb{1}[\tilde{y}_{T,q}^{LR} \neq \tilde{y}_{T,q}^{k-NN}] \cdot \zeta_P, \quad (4.13)$$

wobei $\tilde{y}_{T,q}^{k-NN}$ ein Semi-Label beschreibt, das für den Merkmalsvektor $\mathbf{x}_{T,q}$ mit k -NN-Analyse er-

mittelt wurde, und ζ_P ein (sehr großer) Bestrafungsterm ist. Das Semi-Label $\tilde{y}_{T,q}^{k-NN}$ entspricht der am häufigsten auftretenden Klasse für den Merkmalsvektor $\mathbf{x}_{T,q}$ unter den k nächsten Nachbarn in \overline{TD}_h^{i-1} . Zugleich wird auch das Semi-Label $\tilde{y}_{T,q}^{LR}$ für den Merkmalsvektor $\mathbf{x}_{T,q}$ durch den LR-Klassifikator basierend auf der aktuellen Menge der Trainingsdaten \overline{TD}_h^{i-1} ermittelt. Sind die beiden Semi-Labels unterschiedlich ($\tilde{y}_{T,q}^{LR} \neq \tilde{y}_{T,q}^{k-NN}$), wird diese Instanz $\mathbf{x}_{T,q}$ als *unsicher* betrachtet und beide Semi-Labels als *inkonsistent* bezeichnet. Dieser Fall kann z.B. dann auftreten, wenn die Verteilungen der Daten unterschiedlicher Klassen in \overline{TD}_h^{i-1} eine starke Überlappung aufweisen. Dann können die Instanzen aus der Quelldomäne in \overline{TD}_h^{i-1} , die auf der falschen Seite der Entscheidungsgrenze und im Grenzübergangsbereich liegen, zu einem unsicheren Semi-Label für einen Kandidaten $\mathbf{x}_{T,q}$ für die Inklusion verleiten. Solche unsicheren Kandidaten sollen von der Inklusion in \overline{TD}_h^i ausgeschlossen werden. Dafür wird der Bestrafungsterm ζ_P in Gleichung 4.13 verwendet. Wenn der Wert von \mathcal{Q}_T für einen Kandidaten für die Inklusion $\mathcal{Q}_T(\mathbf{x}_{T,q}) > \zeta_P$ ist, dann wird diese Stichprobe in der aktuellen Iteration verworfen. Damit werden nur Stichproben mit konsistenten Klassenlabels in den hybriden Trainingsdatensatz übernommen. Die Strategie zur Auswahl der Instanzen aus der Zieldomäne ist in Abbildung 4.5 veranschaulicht.

Zur Auswahl der Trainingsbeispiele aus der Zieldomäne für die Inklusion in \overline{TD}_h^i werden in jeder Iteration i zunächst die $\mathcal{Q}_T(\mathbf{x}_{T,q})$ -Werte für jeden Kandidaten in \overline{TD}_T^{i-1} ermittelt. Dann werden alle Kandidaten $\mathbf{x}_{T,q}$ nach dem \mathcal{Q}_T -Wert pro Klasse $y_{T,q} = C^{\kappa}$ aufsteigend sortiert. Anschließend werden aus den pro Klasse sortierten Listen jeweils ρ_T Trainingsbeispiele für jede Klasse mit den kleinsten \mathcal{Q}_T -Werten aus \overline{TD}_T^{i-1} in den hybriden Trainingsdatensatz \overline{TD}_h^i mit dem Semi-Label $\tilde{y}_{T,q} = \tilde{y}_{T,q}^{LR} = \tilde{y}_{T,q}^{k-NN}$ und nur unter der Bedingung $\tilde{y}_{T,q}^{LR} = \tilde{y}_{T,q}^{k-NN}$ aufgenommen. Wegen dieser Bedingung kann es zu einer Situation kommen, dass noch Kandidaten in \overline{TD}_T^{i-1} vorhanden sind, jedoch keine von Ihnen mehr in \overline{TD}_h^i übernommen werden dürfen. Der Adaptionprozess konvergiert, sobald alle Stichproben der Quelldomäne aus dem \overline{TD}_h^{i-1} entfernt wurden und keine Stichproben der Zieldomäne in den \overline{TD}_h^i übernommen werden können, weil \overline{TD}_T^{i-1} leer ist oder keiner der restlichen Stichproben in \overline{TD}_T^{i-1} übernommen werden darf.

Durch die Formulierung der Bewertungsfunktion aus Gleichung 4.13 werden in erster Linie jene Trainingsbeispiele bevorzugt, die in den Bereichen der größeren Dichte der Trainingsbeispiele in dem aktuellen Trainingsdatensatz nahe an den Clusterzentren einer dem Semi-Label entsprechenden Klasse liegen, wobei deren Semi-Labels im oben definierten Sinne nicht unsicher sein dürfen.

4.3.3 Strategie zur Gewichtung der Trainingsbeispiele

Die Beschreibung der Strategien zur Gewichtung der Trainingsbeispiele in diesem Kapitel baut auf den Grundlagen zur Verwendung der individuellen Gewichte für Trainingsbeispiele bei der LR aus Kapitel 4.2.1 auf. Die Strategie zur Gewichtung der Trainingsbeispiele verfolgt hier zwei Ziele. Erstens soll der Einfluss auf die Entscheidungsgrenze von Trainingsbeispielen, die möglicherweise von Fehlern betroffen sind, reduziert werden, und zweitens soll der Einfluss von unerwarteten Veränderungen der Semi-Labels in Verlauf der Adaption, z.B. aufgrund einer Veränderung der

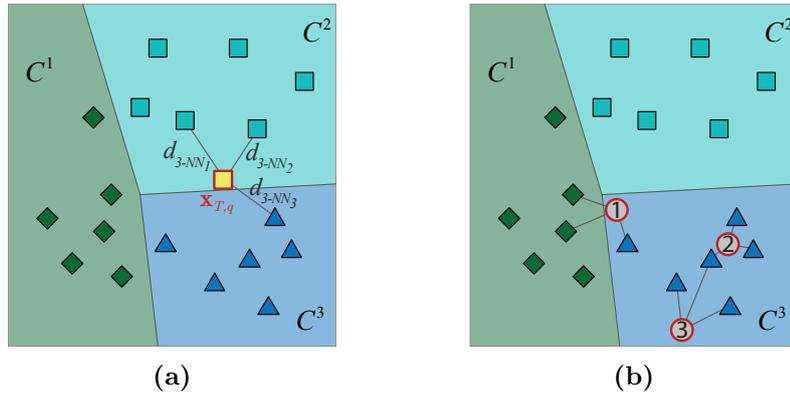


Abbildung 4.5: Beispiel zur Veranschaulichung der Strategie zur Auswahl der Trainingsbeispiele aus der Zieldomäne auf Basis des Kriteriums aus Gleichung 4.13. Im Rahmen der k -NN-Analyse mit $k = 3$ werden jeweils 3 Nachbarn für jeden Kandidaten untersucht. Jedes Beispiel zeigt ein Dreiklassenproblem im Rahmen der DA in einem 2D-Merkmalraum, welcher beim Training in drei Klassenbereiche aufgeteilt wurde, die jeweils farblich markiert sind. Die Instanzen der jeweiligen Klasse sind durch geometrische Figuren repräsentiert. Das Beispiel in (a) veranschaulicht die Strategie zunächst für einen Kandidaten $\mathbf{x}_{T,q}$. Die Ermittlung von \bar{d}_{3-NN} erfolgt als Mittelwert aus den Abständen zu den 3-NN d_{3-NN_1} bis d_{3-NN_3} . Die prädierten Semi-Labels (häufigste Klasse unter den NN) sind konsistent $\tilde{y}_{T,q}^{LR} = \tilde{y}_{T,q}^{3-NN} = C^2$, deswegen darf $\mathbf{x}_{T,q}$ mit dem Semi-Label C^2 in \overline{TD}_h^i übernommen werden. Das Beispiel aus (b) zeigt drei mögliche Kandidaten (durchnummerierte Kreise), von denen nur die Instanzen „2“ und „3“ transferiert werden können, wobei die Instanz „2“ wegen des kleineren durchschnittlichen Abstandes zu den 3-NN bevorzugt wird. Die Instanz „1“ darf wegen der Inkonsistenz der vorhergesagten Semi-Labels ($\tilde{y}_{T,1}^{LR} = C^3$ und $\tilde{y}_{T,1}^{3-NN} = C^1$) nicht übernommen werden.

Entscheidungsgrenze, reduziert werden, um eine stabile Adaption zu gewährleisten. Damit wird im Allgemeinen versucht, plötzliche Änderungen der Modellparameter der LR während der gesamten DA zu vermeiden. Um die aufgestellten Ziele zu erreichen, werden zwei unterschiedliche Ansätze verfolgt, die auf einander aufbauen.

Gewichtung der Trainingsbeispiele. Das erste Teilziel ist es, durch den Einsatz der Gewichte den Einfluss von Trainingsbeispielen, die am wahrscheinlichsten von Fehlern betroffen sind (d.h. falsche Klassenlabels aufweisen), zu reduzieren. Das Gewicht $g_{\overline{TD}_h,n} \in [0, 1]$ des n -ten Trainingsbeispiels in \overline{TD}_h^i zeigt dabei das Vertrauen des Verfahrens in die Korrektheit des Klassenlabels dieses Trainingsbeispiels an. Aus diesem Grund erhalten die gelabelten Instanzen aus der Quelldomäne, deren Labels relativ sicher sind, größere Gewichte als die Instanzen aus der Zieldomäne, deren Semi-Labels als mit einer größeren Unsicherheit behaftet betrachtet werden. Das Gewicht $g_{\overline{TD}_h,n}^i(\mathbf{x}_{\overline{TD}_h,n}) = g_{\mathbf{x}_n}^i$ für ein Trainingsbeispiel $\mathbf{x}_{\overline{TD}_h,n}$ in jeder Iteration i der DA wird wie folgt ermittelt:

$$g_{\mathbf{x}_n}^i = \begin{cases} 1 & \text{falls } \mathbf{x}_{\overline{TD}_h,n} \in \overline{TD}_S^i \wedge y_{S,n} = \tilde{y}_{S,n}^{LR} \\ g(p_n, \gamma) & \text{falls } \mathbf{x}_{\overline{TD}_h,n} \in \overline{TD}_S^i \wedge y_{S,n} \neq \tilde{y}_{S,n}^{LR} \\ g(p_n, \gamma) & \text{falls } \mathbf{x}_{\overline{TD}_h,n} \in \overline{TD}_T^i \end{cases} \quad (4.14)$$

Der Term $g(p_n, \gamma)$ beschreibt dabei eine monoton steigende Gewichtsfunktion, welche auf [Klein und Förstner, 1984] beruht:

$$g(p_n, \gamma) = 1 - \frac{1}{1 + \left(\frac{p_n}{\gamma}\right)^4}, \quad (4.15)$$

wobei $p_n = p(y_{\overline{TD}_h, n} | \mathbf{x}_{\overline{TD}_h, n})$ und γ ein Parameter ist, und zwar jener Wert von p_n , für den $g(p_n = \gamma, \gamma) = 0.5$ gilt. Der Parameter γ muss zur Berechnung vorgegeben werden. Der Verlauf der Gewichtsfunktion $g(p_n, \gamma)$ ist in Abbildung 4.6a dargestellt.

Es wird gemäß der Definition aus Gleichung 4.14 zwischen drei Fällen unterschieden. Für Trainingsbeispiele aus der Quelldomäne mit konsistenten Klassenlabels ($y_{S, n} = \tilde{y}_{S, n}^{LR}$) wird der maximale Wert von 1 für ein Gewicht gesetzt, der das größte Vertrauen in diese Trainingsbeispiele ausdrückt. Es wird hier davon ausgegangen, dass solche Trainingsbeispiele maßgeblich zu der Entscheidungsgrenze des initialen Klassifikators beitragen und eine Grundlage für die Adaption bilden. Im zweiten und dritten Fall wird das initiale Gewicht mit Hilfe einer Gewichtsfunktion $g(p_n, \gamma)$ ermittelt, die die a-posteriori Wahrscheinlichkeit $p_n = p(y_{\overline{TD}_h, n} | \mathbf{x}_{\overline{TD}_h, n})$ als Abstandsmaß für die Entfernung des Trainingsbeispiels $\mathbf{x}_{\overline{TD}_h, n}$ von der Entscheidungsgrenze verwendet. Der Unterschied zwischen den beiden Fällen liegt darin, ob das Trainingsbeispiel $\mathbf{x}_{\overline{TD}_h, n}$ aus der Quell- oder Zieldomäne kommt. Allerdings handelt es sich bei den Instanzen aus der Quelldomäne um Trainingsbeispiele mit inkonsistenten Klassenlabels, die also auf der falschen Seite der Entscheidungsgrenze liegen. Deswegen reduziert sich die a-posteriori Wahrscheinlichkeit p_n und somit das initiale Gewicht $g_{\mathbf{x}_n}^i$ solcher Trainingsbeispiele mit steigendem Abstand zur Entscheidungsgrenze. Der Grund für diese Gewichtungstrategie liegt darin, dass Trainingsbeispiele der einzelnen Klassen aus der Quelldomäne, die auf der falschen Seite der Entscheidungsgrenze liegen, als potentielle Ausreißer betrachtet werden. Es wird dabei angenommen, dass, je weiter entfernt solche Trainingsbeispiele von Entscheidungsgrenze liegen, es desto weniger wahrscheinlich ist, dass sie der Verteilung der entsprechenden Klassen aus der Zieldomäne entsprechen können. Diese Annahme folgt aus der Ähnlichkeitsbedingung der Domänen. Im Gegensatz dazu gibt es für die ungelabelten Instanzen der Zieldomäne keine richtige und falsche Seite von der Entscheidungsgrenze, es wird lediglich versucht, bei der Auswahl der Trainingsbeispiele das Label möglichst gut vorherzusagen. Wie im vorherigen Kapitel bereits erläutert, ist die Wahrscheinlichkeit für eine richtige Prädiktion des Labels in der Nähe der Entscheidungsgrenze niedriger als in einem weiter entfernten Bereich. Aus diesem Grund erhöht sich das Gewicht eines Trainingsbeispiels aus der Zieldomäne mit wachsendem Abstand von der Entscheidungsgrenze im dritten Fall in Gleichung 4.14, weil das Vertrauen in sein Label wächst. Mit der Definition der Gewichte in Gleichung 4.14 wird es daher weniger wahrscheinlich, dass ein Trainingsbeispiel eine allzu große Änderung der Entscheidungsgrenze verursacht, welche z.B. durch Inklusion in bzw. Eliminierung aus dem aktuellen Trainingsdatensatz oder Veränderung eines Semi-Labels hervorgerufen werden könnte.

Iterative Anpassung der Gewichte im Rahmen der Domänenadaption. Während des DA-Prozesses kann es aufgrund von Verschiebung der Entscheidungsgrenze dazu kommen, dass einige Trainingsbeispiele aus der Zieldomäne ihr Semi-Label ändern oder Trainingsbeispiele aus der Quelldomäne, deren Labels früher konsistent waren, fortan Inkonsistenz der Labels aufweisen. Das Modell der Gewichte aus Gleichung 4.14 berücksichtigt zunächst nicht, dass dies auch als ein

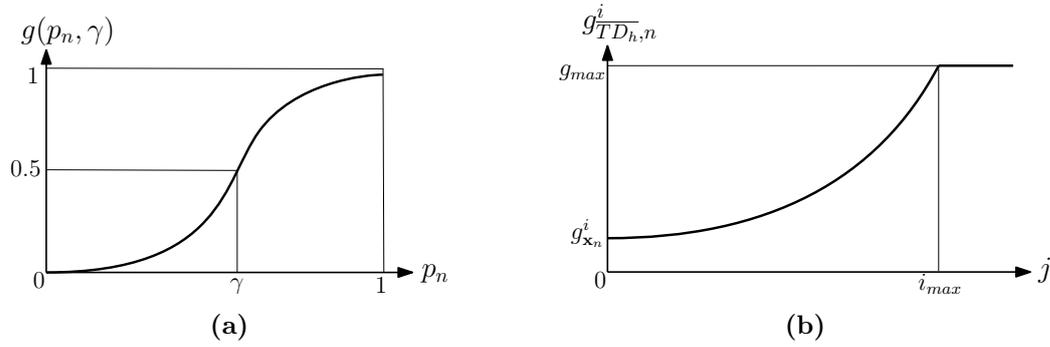


Abbildung 4.6: Gewichtungsfunktionen: (a) Gewichtungsfunktion in Abhängigkeit von der Distanz zur Entscheidungsgrenze gemäß Gleichung 4.15; (b) Iterative Anpassung der Gewichtungsfunktion während der DA gemäß Gleichung 4.16.

Kriterium für die Unsicherheit des Labels eines Trainingsbeispiels angesehen werden kann. Instanzen, die ihr Label seit vielen Iterationen nicht geändert haben, soll mehr Vertrauen geschenkt werden. Es wird dabei davon ausgegangen, dass dadurch der Einfluss von sicheren Instanzen, vor allem der Einfluss von sicheren Trainingsbeispielen aus der Zieldomäne, auf die Entscheidungsgrenze sukzessive erhöht wird. Das Ziel dieser Gewichtsanzpassung ist, die schrittweise Adaption des Klassifikators an die Verteilung der Daten aus der Zieldomäne zu unterstützen. Dafür wird die Definition der Gewichte aus Gleichung 4.14 entsprechend [Chang et al., 2002; Bruzzone und Marconcini, 2009] wie folgt erweitert (Abbildung 4.6b):

$$g_{TD_h,n}^i(\mathbf{x}_{TD_h,n}) = \min \left(g_{\mathbf{x}_n}^i + \frac{(g_{max} - g_{\mathbf{x}_n}^i) \cdot j^2}{(i_{max} - 1)^2}, g_{max} \right), \quad (4.16)$$

In Gleichung 4.16 ist j die Anzahl der Iterationen, für die das Semi-Label eines Trainingsbeispiels aus der Zieldomäne unverändert geblieben ist bzw. für die die Labels eines Trainingsbeispiels aus der Quelldomäne Konsistenz im Sinne der Gleichung 4.12 aufweisen. Dabei ist $g_{\mathbf{x}_n}^i$ das Gewicht des Trainingsbeispiels n in der aktuellen Iteration i der DA aus Gleichung 4.14. Der Parameter i_{max} in Gleichung 4.16 bezeichnet die Anzahl der Iterationen, für die es dem Gewicht erlaubt ist, quadratisch mit j zu wachsen. Der Parameter g_{max} legt dabei das maximal mögliche Gewicht für ein Trainingsbeispiel fest, welches nach i_{max} Iterationen erreicht wird. Das Gewicht des Trainingsbeispiels $\mathbf{x}_{TD_h,n}$ in der Iteration i aus Gleichung 4.16 entspricht dem Gewicht dieses Trainingsbeispiels in dem hybriden Trainingsdatensatz \overline{TD}_h^i , an dem der Klassifikator in der aktuellen Iteration neu trainiert wird.

4.4 Prädiktion von negativem Transfer

Die Verteilungen der Daten aus der Quell- und Zieldomäne können sich bei der DA unterscheiden, müssen aber trotzdem eine gewisse Ähnlichkeit haben, damit ein Wissenstransfer möglich ist. Eine unzureichende Ähnlichkeit der Domänen wirkt sich negativ auf die Zielfunktion $f_T(\cdot)$ aus und kann zu NT (siehe Kapitel 2.2.3) führen [Rosenstein et al., 2005]. Zur Prädiktion von NT wird hier eine neue Methode zur Bestimmung der Ähnlichkeit der Verteilungen der Da-

ten aus beiden Domänen auf Basis der MMD, die in Kapitel 2.3 beschrieben wurde, entwickelt. Die MMD aus [Gretton et al., 2012] misst die Ähnlichkeit zweier Verteilungen als Abstand zwischen den Mittelwerten von deren Wahrscheinlichkeitsverteilungen in einem RKHS. Damit ist die MMD-Metrik sensitiv gegenüber den Differenzen in den Randverteilungen der Daten, z.B. aus der Quell- und Zieldomäne. Die beiden Domänen können sich allerdings auch in der a-posteriori Wahrscheinlichkeitsverteilungen der Klassen bei gegebene Daten unterscheiden. Eine Berücksichtigung dieser Unterschiede könnte die Prädiktion von NT verbessern. Da jedoch keine gelabelten Daten in der Zieldomäne vorliegen, muss dieser Unterschied zwischen den a-posteriori Wahrscheinlichkeitsverteilungen anders berücksichtigt werden. Es wird hier vorgeschlagen, eine Modifikation der Verteilungen aus beiden Domänen unter Berücksichtigung der Verteilung der jeweiligen Klassen in der Quelldomäne vor der Schätzung der MMD zu diesem Zweck vorzunehmen. Die Hypothese hinter der vorgeschlagenen Methode ist, dass eine Modifikation der Verteilungen aus beiden Domänen nach einem gleichen Muster unter Verwendung von a-priori Wissen aus der Quelldomäne (Klassenlabels) die darauf folgende Schätzung der Diskrepanz zwischen den Domänen verbessern kann und somit zu einem besseren Merkmal zur Prädiktion von NT führt. Unter Nutzung der a-posteriori Wahrscheinlichkeiten p^0 aus dem initialen Klassifikator in Iteration $i = 0$ werden zunächst jeweils \tilde{N} Stichproben \mathbf{x}_S und \mathbf{x}_T (Merkmalsvektoren), die zufällig gemäß der Beschreibung in Kapitel 2.3 aus der Quell- und Zieldomäne gezogen wurden, entsprechend folgender Vorschrift verschoben:

$$\mathbf{x}_{new} = \mathbf{x} + \lambda \cdot \frac{\partial p^0}{\partial \mathbf{x}} . \quad (4.17)$$

Nach dieser gleichen Vorschrift werden sowohl Stichproben aus der Quell- als auch der Zieldomäne verschoben. Dabei ist \mathbf{x}_{new} der modifizierte Merkmalsvektor aus der jeweiligen Domäne. Die Verschiebung erfolgt relativ zur Entscheidungsgrenze des Klassifikators in Richtung des Gradienten $\partial p^0 / \partial \mathbf{x}$. Der Parameter $\lambda > 0$ modelliert die Stärke dieser Verschiebung von der Entscheidungsgrenze weg. Die Stärke der Verschiebung hängt außerdem von dem Gradienten $\partial p^0 / \partial \mathbf{x}$ ab. Das bedeutet, dass einzelne Stichproben unterschiedlich stark verschoben werden: je weiter von der Entscheidungsgrenze, desto kleiner die Stärke der Verschiebung. Die vorgeschlagene Modifikation ist in Abbildung 4.7 veranschaulicht. Durch die Modifikation der Verteilungen aus der Quell- und Zieldomäne gemäß der Vorschrift aus Gleichung 4.17 soll die MMD sensitiver auf Differenzen in der Verteilung der entsprechenden Klassen aus der Quell- und Zieldomäne gemacht werden. Es wird dabei von der folgenden Annahme ausgegangen: Wenn a-posteriori Wahrscheinlichkeitsverteilungen der Klassen in den beiden Domänen unterschiedlich sind, werden sich deren Randverteilungen durch die vorgeschlagene Modifikation stärker unterscheiden, wobei die Unterschiede in den Randverteilungen mit Hilfe der MMD gemessen werden können. Zwischen den beiden geänderten Verteilungen von Daten aus der Quell- und Zieldomäne, die entsprechend der Gleichung 4.17 modifiziert wurden, wird anschließend die neue MMD-Distanz d_{MMD_m} berechnet (siehe Abbildung 4.7).

Bevor d_{MMD_m} für die jeweilige Quell- und Zieldomäne berechnet wird, muss der Parameter λ für die Verschiebung der Daten bestimmt werden. Dafür wird zunächst der allgemeine Funktionsverlauf d_{MMD_m} in Abhängigkeit von λ betrachtet. Experimentelle Untersuchungen auf verschiedenen

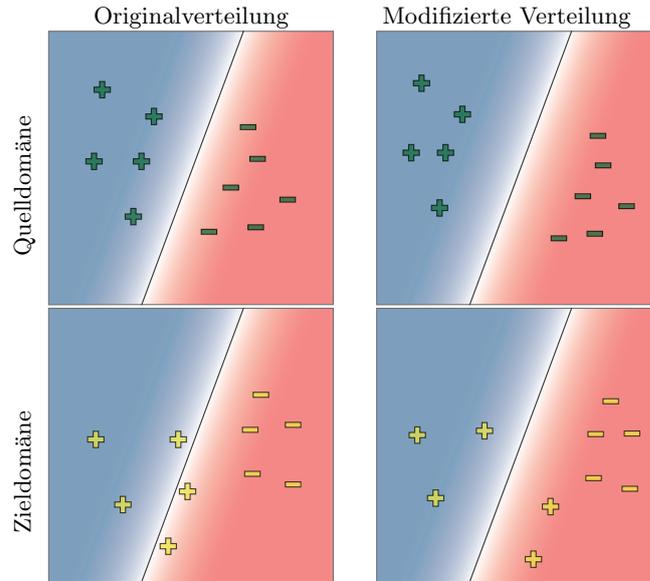


Abbildung 4.7: Vereinfachtes Beispiel zur Veranschaulichung der Strategie zur Modifikation von Verteilungen der Daten aus der Quell- und Zieldomäne. Die Abbildung zeigt exemplarisch die Verteilung der Daten aus der Quell- und Zieldomäne vor und nach der Modifikation gemäß Gleichung 4.17 in einem 2D-Merkmalraum für ein Zweiklassenproblem. Trainingsbeispiele aus der jeweiligen Klasse sind als Plus- und Minuszeichen dargestellt. Der Merkmalsraum ist durch die Entscheidungsgrenze des Klassifikators, der an den gelabelten Daten der Quelldomäne angelernt wurde, in zwei Teile aufgeteilt. Die Verschiebung erfolgt in Richtung des Gradienten der a-posteriori Wahrscheinlichkeitsverteilung weg von der Entscheidungsgrenze ($\lambda > 0$). Die Stärke der Verschiebung hängt dabei von dem Wert des Gradienten ab, welcher in der Abbildung durch die Helligkeit repräsentiert wird: je heller die Farbe, desto größer der Wert.

realen Daten haben ergeben, dass die Funktion $d_{\text{MMD}_m}(\lambda)$ allgemeinen Verlauf aus Abbildung 4.8 aufweist. Die Verläufe der Funktion in den Experimenten unterscheiden sich nur darin, wie stark sie gegenüber dem Verlauf aus Abbildung 4.8 gestreckt bzw. gestaucht entlang der horizontalen und/oder vertikalen Achse sind. Diese Form entspricht dem Verlauf einer unimodalen Funktion mit einem einzigen Maximum an der Stelle λ_{opt} . Eine effiziente Lösung zur Bestimmung der Stelle von Maximum in unimodalen Funktionen bietet die Methode des Goldenen Schnittes, die bereits in Kapitel 2.3 bei der Schätzung der Bandbreite für die MMD beschrieben wurde. Dabei wird nach dem Wert von λ_{opt} gesucht, der die Schätzung der MMD_m maximiert. Da der Verlauf von $d_{\text{MMD}_m}(\lambda)$ in Abbildung 4.8 unimodal ist, wird der Algorithmus aus Tabelle 2.1 hier zur Suche nach λ_{opt} entsprechend vereinfacht. Der vollständige Algorithmus zur Bestimmung von λ_{opt} wird in Tabelle 4.1 vorgestellt. Zu Beginn der Bestimmung des Parameters λ_{opt} stehen am Eingang jeweils zwei unabhängige Stichproben aus der Quell- und Zieldomäne $\mathbf{x}_{S,\text{new}}, \mathbf{x}'_{S,\text{new}}, \mathbf{x}_{T,\text{new}}$ und $\mathbf{x}'_{T,\text{new}}$ zur Verfügung, die gemäß der Vorschrift aus Gleichung 4.17 bereits modifiziert wurden. Die Schätzung des Parameters λ_{opt} erfolgt dabei in mehreren Iterationsschritten analog zu der Beschreibung aus Kapitel 2.3. Die Anzahl der Iterationen ist durch die Variable *MaxIter* festgelegt und ist bei der Bestimmung von λ_{opt} überall auf 10 Iterationen begrenzt. Die Bestimmung von d_{MMD_m} erfolgt gemäß Gleichung 2.12 aus Kapitel 2.3. Dabei muss in jeder Iteration für jede neue Verschiebung (λ_A und λ_B) die Bandbreite σ_{MMD} gemäß dem Algorithmus aus Tabelle 2.1 neu geschätzt werden. Am Ende des Algorithmus zur Ermittlung von λ_{opt} wird dieser Parameter

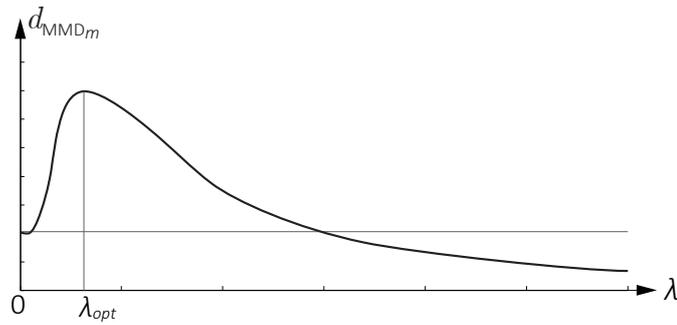


Abbildung 4.8: Allgemeine Form der MMD_m -Distanz ($d_{MMD_m}(\lambda)$) in Abhängigkeit von dem Wert des Parameters λ .

zur Berechnung von $d_{MMD_m}(\lambda_{opt})$ verwendet. Die Bestimmung von d_{MMD_m} auf Basis der zufällig ausgewählten Stichproben unterliegt einer gewissen Variabilität der Ergebnisse. Deswegen wird hier die BAGGING-Methode eingesetzt, um die Robustheit der Berechnung zu verbessern. Dabei wird die Schätzung der MMD mehrmals unter Verwendung von unterschiedlichen, unabhängigen Ziehungen der zufälligen Bootstrap Stichproben aus der jeweiligen Verteilung wiederholt. Die Anzahl der Bootstrap-Iterationen ist sowohl zur Schätzung der Bandbreite σ_{MMD} als auch zur Bestimmung des Parameters λ_{opt} in dieser Arbeit auf 10 begrenzt. Die resultierende Distanz d_{MMD_m} wird als Mittelwert aus den unabhängigen Berechnungen berechnet.

Auf die berechnete modifizierte Distanz d_{MMD_m} zwischen zwei Domänen wird dann ein Schwellwert τ_{MMD_m} angewendet, um die Fälle von NT vorherzusagen. Ist NT zu erwarten, wird der Klassifikator aus der Quelldomäne unmittelbar auf die Zieldomäne angewandt ($f_T = f_S$). Andernfalls wird die DA eingeleitet.

4.5 Diskussion

Das vorgestellte Verfahren wurde zur Klassifikation von Luftbildern entwickelt. Im Gegensatz zu den traditionellen Methoden des maschinellen Lernens stehen hier keine gelabelten Trainingsdaten in dem zu klassifizierenden Bild zur Verfügung. Der Klassifikator wird an Daten aus einer ähnlichen Szene (der Quelldomäne) angelernt und mit Hilfe der DA an die Verteilung des Zielbildes angepasst. Im Gegensatz zu anderen Verfahren aus der Literatur, die Transfer von Instanzen zum Anpassen des Klassifikators an die Zieldomäne verwenden, wird ein einfacher LR-Klassifikator für diese Aufgabe verwendet. Die LR ist ein Klassifikator mit geringer Rechenkomplexität und mit einem probabilistischen Output, sie kann auf einfache Weise auf Mehrklassenprobleme angewandt werden. Das Konzept der iterativen Anpassung wurde von Bruzzone und Marconcini [2010] inspiriert, die allerdings auf einem SVM-Klassifikator aufbauen. Aufgrund der unterschiedlichen Trainingsparadigmas der Klassifikatoren (Probabilistische Schätzung vs. Maximum-Margin-Training) müssen die Strategien zur Auswahl der auszutauschenden Trainingsbeispiele und der Prozess der Schätzung der aktuellen Parameter anders definiert werden.

Tabelle 4.1: Ermittlung des Parameters für die Stärke der Verschiebung λ_{opt} aus Gleichung 4.17 mit der Methode des Goldenen Schnittes.

Algorithmus: Ermittlung des Parameters λ_{opt}

Eingabe: $\mathbf{x}_{S,new}$, $\mathbf{x}'_{S,new}$, $\mathbf{x}_{T,new}$, $\mathbf{x}'_{T,new}$, $MaxIter$

Ausgabe: λ_{opt}

$\varphi := 1.61803398875$

$L := 0$

$R := \frac{\pi}{2}$

for $i = 1 : MaxIter$ **do**

$A = R - \frac{R-L}{\varphi}$

$B = L + \frac{R-L}{\varphi}$

$\mathbf{f}_A = d_{MMD_m}^2(S, T)$ für $\lambda_A = \tan(A)$

$\mathbf{f}_B = d_{MMD_m}^2(S, T)$ für $\lambda_B = \tan(B)$

if $\mathbf{f}_B < \mathbf{f}_A < 0$ **then**

$R = B$

else

$L = A$

end if

end for

return $\lambda_{opt} = \tan\left(\frac{L+R}{2}\right)$

Die Modifikation der Verteilungen aus Kapitel 4.4 zur darauffolgenden Berechnung der MMD-Metrik im Kontext von NT ist ein Versuch, die a-posteriori Wahrscheinlichkeitsverteilung der Klassen $p(y|\mathbf{x})$ aus der Quelldomäne in die auf der Randverteilung $p(\mathbf{x})$ basierende MMD-Metrik einzubeziehen. Es wird erwartet, dass dadurch besseres Merkmal zur Prädiktion von NT erzeugt wird. Eine Schwachstelle der vorgeschlagenen Modifikation liegt in der Abhängigkeit von einem Parameter λ , welcher von der jeweiligen Verteilung der Daten in der Quell- und Zieldomäne abhängig ist und für jeden Fall separat bestimmt werden muss. Dem Problem wird mit Hilfe der Methode des goldenes Schnittes begegnet. Dabei wird analog zu [Sriperumbudur et al., 2009] (siehe Kaitel 2.3) nach jenem Wert von λ gesucht, der die Schätzung der vorgeschlagenen MMD_m -Distanz maximiert.

Im Rahmen der vorgestellten Ansätze zur DA und Prädiktion von NT wird eine Reihe von Hyperparametern verwendet, die eingestellt werden müssen. Eine Übersicht über diese Parameter bietet Tabelle 4.2.

Tabelle 4.2: Übersicht über die in der Methodik beschriebenen Parametern des entwickelten Ansatzes zur DA und zur Prädiktion von NT, die vom Benutzer vorgegeben werden müssen. Die Einstellung der Parameter 1–9 ist zur Durchführung der DA erforderlich, wobei der Parameter 1 (σ_0) für das initiale Training des Klassifikators an den Daten der Quelldomäne verwendet wird und die Parameter 2–9 unmittelbar zur DA eingesetzt werden. Der Schwellwertparameter τ_{MMD_m} (Nummer 10) wird zur Erkennung von NT benötigt.

Nr.	Parameter	Beschreibung
1	σ_0	Parameter zur Steuerung der Regularisierung während des initialen Trainings des Klassifikators (Kapitel 4.3.1, Gleichung 4.7)
2	σ_{DA}	Parameter zur Steuerung der Regularisierung während der Domänenadaption (Kapitel 4.3.1, Gleichung 4.7)
3	ρ_S	Anzahl der pro Klasse auszutauschenden Trainingsbeispiele aus der Quelldomäne in einer Iteration der Domänenadaption (Kapitel 4.3.1)
4	ρ_T	Anzahl der pro Klasse auszutauschenden Trainingsbeispiele aus der Zieldomäne in einer Iteration der Domänenadaption (Kapitel 4.3.1)
5	k	Anzahl der Nachbarn k bei der k -NN Analyse fürs Kriterium zur Auswahl der Trainingsbeispiele aus der Zieldomäne (Kapitel 4.3.2)
6	γ	Parameter der Gewichtsfunktion $g(p_n, \gamma)$ (Kapitel 4.3.3, Gleichung 4.15)
7	i_{max}	Parameter für die Anzahl der Iterationen aus der Funktion zur Anpassung des Gewichtes (Kapitel 4.3.3, Gleichung 4.16)
8	$g_{S,max}$	Maximal mögliches Gewicht eines Trainingsbeispiels aus der Quelldomäne in der Funktion zur Anpassung des Gewichtes (Kapitel 4.3.3, Gleichung 4.16)
9	$g_{T,max}$	Maximal mögliches Gewicht eines Trainingsbeispiels aus der Zieldomäne in der Funktion zur Anpassung des Gewichtes (Kapitel 4.3.3, Gleichung 4.16)
10	τ_{MMD_m}	Schwellwertparameter, der auf die MMD_m Distanz zwischen den modifizierten Verteilungen aus Quell- und Zieldomäne zur Prädiktion von NT angewendet wird (Kapitel 4.4)

5 Aufbau der Experimente

In diesem Kapitel wird das Vorgehen zur Evaluierung des entwickelten Ansatzes zur Domänen-adaption vorgestellt. Zuerst werden in Kapitel 5.1 die Testdaten beschrieben, welche bei den Experimenten verwendet wurden. In Kapitel 5.2 wird der allgemeine Untersuchungsablauf der Experimente beschrieben. Kapitel 5.3 gibt ein Überblick über die verwendeten Bewertungskriterien, während Kapitel 5.4 sich speziell mit der Evaluierung der DA beschäftigt. Anschließend erfolgt in Kapitel 5.5 eine Beschreibung der Merkmale bis hin zu Definition der Merkmalsräume für die DA.

5.1 Testgebiete

Zur Evaluierung des entwickelten Ansatzes stehen Luftbilder aus fünf unterschiedlichen Testgebieten \mathfrak{T} zur Verfügung, die eine ausgiebige Analyse des Ansatzes ermöglichen. Diese umfassen die deutschen Städte Vaihingen ($\mathfrak{T}^{Vaihingen}$), Potsdam ($\mathfrak{T}^{Potsdam}$), Buxtehude ($\mathfrak{T}^{Buxtehude}$), Hannover ($\mathfrak{T}^{Hannover}$) und Nienburg ($\mathfrak{T}^{Nienburg}$). Die Bilder der Testgebiete zeigen typische städtische Landschaften, wobei die Städte sich hinsichtlich der Größe, Grad der Urbanisierung und Architektur unterscheiden: von kleinen, niedrigen und freistehenden Häusern und Gebäuden wie bei *Vaihingen* oder *Buxtehude* bis hin zu großen Gebäudeblöcken und langen, schmalen Straßen wie bei *Potsdam* oder *Hannover*. Die Bilder weisen außerdem verschiedene saisonale Effekte aufgrund der unterschiedlichen Jahreszeiten während der Aufnahme auf. Dies führt z.B. zu einer unterschiedlichen Ausprägung der Vegetation zwischen den Testgebieten: angefangen mit Vegetation in der Revitalisierungsphase im Frühjahr wie bei *Nienburg* über die Sommerphase bei *Vaihingen*, während der die Vegetation am vitalsten ist, bis hin zur Rückbildung der Vegetation im Herbst bei *Potsdam*. Ein Beispielbild aus dem jeweiligen Testgebiet zeigt die Abbildung 5.1.



(a) Vaihingen (b) Potsdam (c) Buxtehude (d) Hannover (e) Nienburg

Abbildung 5.1: Bildausschnitte aus den fünf Testgebieten in Farbinfrarotdarstellung (CIR).

Bildmaterial. Das Bildmaterial für die Testgebiete *Vaihingen* und *Potsdam* wurde von der *International Society for Photogrammetry and Remote Sensing* (ISPRS) aus dem *2D Semantic Labeling Contest* zur Verfügung gestellt [Wegner et al., 2016]. Das Bildmaterial für die Testgebiete *Buxtehude*, *Hannover* und *Nienburg* wurde aus der Kooperation mit dem Institut für Informationsverarbeitung (TNT) an der Leibniz Universität Hannover bezogen und stammt vom Landesamt für Geoinformation und Landesvermessung Niedersachsen² (LGLN).

Das Testgebiet *Vaihingen* ist in 33 rechteckige Bildkacheln aufgeteilt, die ohne Überschneidung nebeneinander liegen. Die Kacheln haben unterschiedliche Ausdehnung von ca. 100 m bis 300 m in Breite bzw. Höhe. Die Bodenpixelgröße (en: *ground sampling distance*: GSD) beträgt 8 cm. Beim Testgebiet *Potsdam* ist eine größere Region in 38 nebeneinander liegende quadratische Kacheln unterteilt. Jede Kachel ist gleichgroß und bildet ein $300m \times 300m$ großes Areal ab. Die GSD beträgt hier 5 cm. Alle Bilder wurden jedoch für die nachfolgende Tests im Rahmen der Evaluierung mit Hilfe der bilinearen Interpolation mit dem Faktor $5/8$ skaliert, um die zu *Vaihingen* gleiche GSD von 8 cm zu erhalten. Die Testgebiete *Buxtehude*, *Hannover* und *Nienburg* umfassen jeweils 9 Bildkacheln (3×3) der Größe von etwa $667 \times 667 m^2$. Die Bodenpixelgröße beträgt jeweils 20 cm und blieb während der Evaluierung unverändert. Zu jeder Kachel ist ein Digitales Oberflächenmodell (DOM), ein Labelbild mit Referenzdaten, in dem jedem Pixel der jeweiligen Bildkachel ein numerischer Schlüssel des zugehörigen Objektes (Klassenlabel) zugewiesen wurde, und je nach Testgebiet ein Digitales Orthophoto (DOP) oder ein True Orthophoto (TOP) gegeben. Dabei liegen TOP für die Testgebiete *Vaihingen* und *Potsdam* und DOP für die Testgebiete *Buxtehude*, *Hannover* und *Nienburg* vor. Ein DOM beschreibt dabei pixelweise die Höhe des Geländes inklusive Objekten auf dem Gelände. Ein digitales Geländemodell DGM beschreibt im Unterschied zu DOM nur die Höhe des Geländes selbst. Die DOP bzw. TOP stehen im TIFF Format mit einer radiometrischen Auflösung von 8 Bit zur Verfügung und bestehen mit Ausnahme von *Vaihingen* aus den vier Bändern: Rot (R), Grün (G), Blau (B) und nahes Infrarot (NIR); im Fall von *Vaihingen* fehlt der Blaukanal. Um gemäß den Annahmen der DA den gleichen Merkmalsraum zu schaffen, wurde der Blaukanal B in allen Bildern, in denen er enthalten ist, entfernt und die Kanäle für alle Bildkacheln wie folgt umsortiert: NIR-R-G. Ein DOP unterscheidet sich von einem TOP dadurch, dass bei seiner Erstellung ein DGM und bei der Erstellung des TOP ein DOM als Grundlage verwendet wird. Dabei werden in dem TOP Gebäude und Vegetation lagerichtig abgebildet. Die DOM Daten wurden mit Hilfe der Bildzuordnung extrahiert und bestehen aus TIFF Dateien mit nur einem Band, deren Grauwerte als Gleitkommazahlen mit 32 Bit kodiert sind und den Höhen in [m] entsprechen.

Die vorgestellten Testgebiete stellen eine gute Grundlage zur nachfolgenden Evaluierung der DA dar. Die Testgebiete sind untereinander räumlich disjunkt und haben unterschiedliche Aufnahmezeiten, die Städte haben unterschiedliche Bebauungsstruktur und Grad der Urbanisierung, die Aufnahmen der Testgebiete weisen unterschiedliche Beleuchtungsverhältnisse und saisonale Effekte (z.B. Ausprägung der Vegetation und Belaubung der Bäume) auf. Die Bildkacheln innerhalb der jeweiligen Testgebiete sind ebenso disjunkt. Die Informationen zu den Testgebieten sind in Tabelle 5.1 kurz zusammengefasst.

Tabelle 5.1: Allgemeine Informationen zum Bildmaterial einzelner Testgebiete für Experimente. Die Abkürzung DOM steht für *Digitales Oberflächenmodell*; TOP für *True Orthophoto*; DOP für *Digitales Orthophoto*; GSD für *Bodenpixelgröße*; NIR für *Nahes Infrarot*; ISPRS für *Internationale Gesellschaft für Photogrammetrie und Fernerkundung*; TNT für *Institut für Informationsverarbeitung* an der Leibniz Universität Hannover.

Testgebiet	Bildmaterial							
	Kanäle	DOM	Orthophoto	GSD	Kacheln	Klassen	Referenzdaten	Bildflug
Vaihingen	NIR-R-G	✓	TOP	8 cm	33	6	manuell, ISPRS	Jul./Aug. 2008
Potsdam	R-G-B-NIR	✓	TOP	5 cm	38	6	manuell, ISPRS	Oktober 2012
Buxtehude	R-G-B-NIR	✓	DOP	20 cm	9	10	manuell, TNT	Mai 2012
Hannover	R-G-B-NIR	✓	DOP	20 cm	9	10	manuell, TNT	April 2010
Nienburg	R-G-B-NIR	✓	DOP	20 cm	9	10	manuell, TNT	April 2011

Klassenstruktur. Die Referenzdaten GT der Testgebiete besitzen teilweise unterschiedliche Objektklassen. Die GT der Testgebiete Vaihingen und Potsdam unterscheiden insgesamt 6 Objektklassen und die der Testgebiete Buxtehude, Hannover und Nienburg beinhalten ursprünglich 10 Objektkategorien, von denen einige die Landnutzung beschreiben. Aus den Grundannahmen der DA folgt die Anforderung nach einer identischen Klassenstruktur für die Quell- und Zieldomäne $\mathcal{Y}_S = \mathcal{Y}_T$ (siehe Kapitel 2.2.1). Aus diesem Grund werden die Klassen aller 5 Testgebiete zur Evaluierung des Ansatzes auf eine gemeinsame Menge der Bodenbedeckungsklassen abgebildet. Dabei bekommt jedes Pixel einer Bildkachel genau eine Objektklasse zugeordnet. Es werden 5 gemeinsame Objektklassen für alle Testgebiete unterschieden: *Versiegelte Fläche*, *Gebäude*, *Niedrige Vegetation*, *Baum* und restliche nicht einzuordnende Daten als Klasse *Sonstiges*. Die relativ kleine, ursprünglich vorhandene Klasse *Auto* wird der Klasse *Versiegelte Fläche* zugeordnet. Einerseits ist die Klasse *Auto* keine relevante Objektkategorie bei der Erstellung von Karten. Andererseits ist ein Auto meist ein Indiz für die Objektkategorie *Versiegelte Fläche*.

5.2 Allgemeiner Untersuchungsablauf

Die durchzuführenden Experimente dienen dem Zweck, die Leistungsfähigkeit des entwickelten Ansatzes zur DA auf realen Daten zu evaluieren. Unterschiedliche experimentelle Untersuchungen verfolgen dabei spezifische Ziele. Die erste Gruppe der Untersuchungen geht auf den Einfluss der unterschiedlichen Parameter auf das Modell der DA und der Prädiktion von NT ein. Das Hauptziel der zweiten Gruppe der Untersuchungen liegt in der empirischen Überprüfung der in der Einleitung aufgestellten Forschungsfragen. Die experimentelle Untersuchungen \mathcal{U} lassen sich also nach deren Zielsetzung thematisch wie folgt aufzuteilen:

- \mathcal{U}_1 : Untersuchung der Parameter der DA
- \mathcal{U}_2 : Analyse der Prädiktion von NT
- \mathcal{U}_3 : Evaluierung der Leistungsfähigkeit der DA

- \mathfrak{U}_4 : Evaluierung der Prädiktion von NT
- \mathfrak{U}_5 : Vergleich mit einem Standardverfahren

Die Untersuchungen erfolgen auf 5 verschiedenen Datensätzen \mathfrak{D} , die aus Bildkacheln der zur Verfügung stehenden Testgebiete (siehe Abbildung 5.2) gebildet wurden. Diese werden wie folgt bezeichnet: *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* und *POOL5*. Die Datensätze *Vaihingen* und *Potsdam* beinhalten jeweils nur die Bilddaten der gleichnamigen Testgebiete. Die restlichen Datensätze kombinieren verschiedene Testgebiete miteinander, um den DA Ansatz auf den Daten mit unterschiedlichen Charakteristika, z.B. in der Bebauungsstruktur oder aufgrund von saisonalen Effekten, aber auch mit unterschiedlicher Bodenpixelgröße (siehe Kapitel 5.1), evaluieren zu können. Die Datensätze *3CITYDS* oder *POOL2* beinhalten zunächst nur Bilddaten der Testgebiete mit derselben Bodenpixelgröße von *20cm* bzw. *8cm*. Dabei werden die Städte (Testgebiete) *Burtehude*, *Hannover* und *Nienburg* in dem Datensatz *3CITYDS* und die Städte *Vaihingen* und *Potsdam* in dem Datensatz *POOL2* zusammengefasst. Der Datensatz *POOL5* beinhaltet hingegen Bilddaten aus allen 5 Testgebieten. Folglich weisen die gebildeten Datensätze Unterschiede in Bezug auf die Aufnahmesensorik, Lichtverhältnisse, saisonale Effekte sowie auf die Bodenpixelgröße auf, die je nach Datensatz unterschiedlich stark ausgeprägt sind. Sie stellen damit eine solide Grundlage für die Untersuchungen dar. In jeder Untersuchung wird nur ein Teil der Bilddaten eines Testgebietes verwendet, deren exakte Zusammensetzung in dem jeweiligen Experiment erläutert wird. Insbesondere überschneiden sich die verwendete Bildkacheln aus den Untersuchungen \mathfrak{U}_1 und \mathfrak{U}_2 mit denen aus den Untersuchungen \mathfrak{U}_3 bis \mathfrak{U}_4 nicht. Damit wird die Unabhängigkeit der Evaluierungsergebnisse von den Experimenten zur Einstellung der Parameter garantiert.

Ein einzelnes Experiment in Rahmen einer Untersuchung besteht weiterhin aus einer Reihe von Tests. Im Kontext der DA benötigt jeder Test eine Quelle (d.h. Daten, an denen trainiert wird) und ein Ziel (d.h. Daten, an die angepasst wird und an denen getestet wird). Die exakte Beschreibung der Quell- und Zieldaten findet bei der Darstellung der Experimente statt; meist bilden die Daten einer Kachel eine Quelldomäne und die Daten einer anderen Kachel eine Zieldomäne. Alle möglichen Kombinationen der Quell und Zieldomänen in einem Datensatz bilden eine Testreihe zu einem Experiment. Durch Verwendung aller möglichen Kombinationen wird die Verzerrung der Ergebnisse aufgrund der Auswahl von Quell- und Zieldaten minimiert. Eine solche Auswahl entspricht der mathematischen Variation mit Wiederholung, bei der 2 aus insgesamt ν Domänen, die in einem Datensatz zur Verfügung stehen, für ein Test ausgewählt werden. Damit ist die Anzahl der einzelnen Tests in einem Experiment von der Größe des jeweiligen Datensatzes abhängig und beträgt ν^2 .

Die Auswahl der Daten (Stichproben) sowohl aus der Quell- als auch aus der Zieldomäne zum Trainieren bzw. Anpassen des Klassifikators erfolgt mittels eines *Grid Samplings* in einem vordefinierten Raster, welches eine Art der *systematischen Ziehung* (einfache Zufallsstichprobe) [Lohr, 2009] ist. Für Stichproben aus der Quelldomäne stehen Labels zur Verfügung, welche zusammen einen Trainingsdatensatz bilden. Für Stichproben aus der Zieldomäne sind dagegen keine Labels verfügbar. Die Anzahl der Stichproben ist über einen Parameter für die Rasterweite *RW*

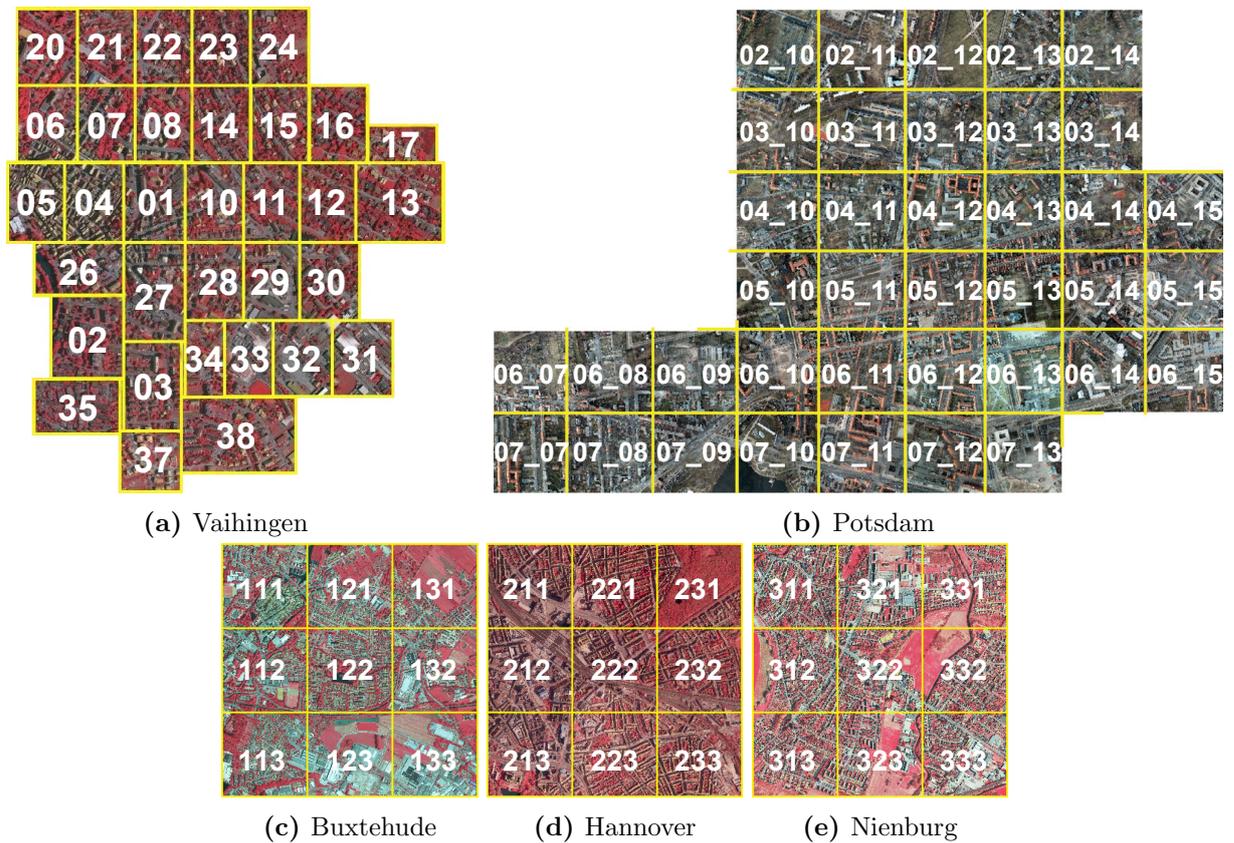


Abbildung 5.2: Konstellation der Bildkacheln in dem jeweiligen Testgebiet mit der zugehörigen numerischen Kodierung.

justierbar: je größer RW , desto weniger Stichproben werden extrahiert. Eine reduzierte Stichprobenmenge für die Quelldomäne heißt in diesem Fall, dass weniger gelabelte Trainingsdaten zur Verfügung gestellt werden müssen. Zugleich wird durch eine kleinere Trainingsdatenmenge die Prozessierungszeit des Trainings und der DA reduziert. Das Grid Sampling ist sehr effizient, kann allerdings manchmal nicht repräsentative Stichproben liefern. Außerdem ist es nicht in Bezug auf die einzelnen Klassen balanciert. Durch die systematische Stichprobenentnahme ist aber eine Verteilung der Trainingsdaten über das ganze Bild gegeben, sodass das komplette Spektrum der Merkmalsverteilung der Klassen abgebildet werden kann. Außerdem sind die Ergebnisse bei dieser Art der Stichprobenentnahme reproduzierbar.

5.3 Kriterien für die Bewertung

Zur quantitativen Auswertung der Ergebnisse eines Experiments (z.B. der Genauigkeit der DA) werden verschiedene Bewertungskriterien verwendet, die im Folgenden erläutert werden. Diejenigen Kriterien, welche zur Bewertung einer spezifischen Serie von Experimenten eingesetzt werden, werden in den entsprechenden Abschnitten aufgeführt.

Konfusionsmatrix und daraus abgeleitete Maße. Eine quantitative Auswertung der pixelweisen Klassifikationsergebnisse erfolgt auf Basis der *Konfusionsmatrix* \mathcal{M} . Die Konfusionsmatrix

ergibt sich aus dem Vergleich der Labels für alle Pixel im Ergebnisbild (nach der Klassifikation oder der DA) mit den korrespondierenden Klassenlabels im Referenzbild. In Folge des Vergleichs entstehen richtige (Label identisch mit Referenzklasse) und falsche (Label weicht von der Referenzklasse ab) Korrespondenzen. Die entstandenen Korrespondenzen für die Labels aus dem Ergebnisbild und Klassen aus dem Referenzbild werden je nach Label und Klasse gezählt und in die Konfusionsmatrix eingetragen. Dabei entspricht die Anzahl der Zeilen und Spalten in der Matrix der Anzahl der Klassen im Referenzbild. Die Einträge in den Zeilen beschreiben die Korrespondenzen für das Klassifikationsergebnis und die Einträge in den Spalten die Korrespondenzen für Referenzklassen. Somit ergibt sich ein Matrixeintrag \mathcal{M}_{lc} in der Zeile l und Spalte c aus Anzahl der Pixelkorrespondenzen für das Ergebnis l und die Referenzklasse c (siehe Beispiel in Tabelle 5.2). Demzufolge steht auf der Hauptdiagonale ($l = c$) die Anzahl der korrekt klassifizierten Pixel einer Klasse und im Rest der Matrix sind die Werte mit der Anzahl der falsch klassifizierten Pixel verteilt. Aus der Konfusionsmatrix lassen sich unterschiedliche Genauigkeitsmaße einer Klassifikation, z.B. nach der DA, ableiten. Die Gesamtgenauigkeit (en: *Overall Accuracy*, OA) erlaubt eine allgemeine Aussage über die durchschnittliche Güte der Klassifikation. Sie ergibt sich aus dem Quotienten der Anzahl der korrekt klassifizierte Pixel und der Gesamtzahl aller Pixel [Hänsch und Hellwich, 2017]:

$$\text{Gesamtgenauigkeit} \quad \text{OA} = \frac{\sum_c \mathcal{M}_{cc}}{\sum_l \sum_c \mathcal{M}_{lc}} \cdot 100\%. \quad (5.1)$$

Die OA erlaubt jedoch keine Aussagen in Bezug auf die einzelne Klassen. Für eine vollständige Analyse kommen deswegen hier klassenspezifische Genauigkeitsmaße wie *Korrektheit* (en: *Correctness*) und *Vollständigkeit* (en: *Completeness*) sowie das *F1-Maß* zum Einsatz [Rutzinger et al., 2009; Powers, 2011]:

$$\text{Korrektheit [\%]} \quad \text{Corr}_c = \frac{\mathcal{M}_{cc}}{\sum_c \mathcal{M}_{lc}} \cdot 100\%, \quad (5.2)$$

$$\text{Vollständigkeit [\%]} \quad \text{Comp}_c = \frac{\mathcal{M}_{cc}}{\sum_l \mathcal{M}_{lc}} \cdot 100\%, \quad (5.3)$$

$$\text{F1-Maß [\%]} \quad \text{F1}_c = \frac{2 \cdot \text{Comp}_c \cdot \text{Corr}_c}{\text{Comp}_c + \text{Corr}_c}. \quad (5.4)$$

Die Korrektheit Corr_c beschreibt den prozentualen Anteil der korrekt klassifizierten Bildprimitiven einer Klasse c unter allen Bildprimitiven, für die die Klasse c prädiziert wurde. Die Vollständigkeit Comp_c bewertet den prozentualen Anteil der vom Klassifikator richtig erkannten Pixel einer Klasse c unter allen Bildprimitiven dieser Klasse aus der Referenz. Bei einer guten Klassifikation sollen die beiden Maße Corr und Comp hohe Werte aufweisen. Eine Kombination der beiden Werte liefert das *F1-Maß* aus Gleichung 5.4, das als harmonisches Mittel aus Korrektheit und Vollständigkeit definiert wird.

Box-Plot Diagramm. Das Box-Plot Diagramm ist eine Methode zur graphischen Darstellung von gestreuten Daten durch ihre Quartile [Velleman und Hoaglin, 1981]. Verschiedene Charakteristika (z.B. Klassifikationsgenauigkeit), die durch Box-Plot Diagramm abgebildet werden,

Tabelle 5.2: Aufbau einer Konfusionsmatrix eines Dreiklassenproblems als Beispiel.

		Referenzklassen		
		Objektklasse 1	Objektklasse 2	Objektklasse 3
Prädizierte Klassen	Objektklasse 1	\mathcal{M}_{11}	\mathcal{M}_{12}	\mathcal{M}_{13}
	Objektklasse 2	\mathcal{M}_{21}	\mathcal{M}_{22}	\mathcal{M}_{23}
	Objektklasse 3	\mathcal{M}_{31}	\mathcal{M}_{32}	\mathcal{M}_{33}

erlauben eine vereinfachte Analyse der Daten (siehe Abbildung 5.3). Das Box-Plot Diagramm besteht aus einer Box, deren untere und obere Grenze dem 25%-Quartil (Q_{25}) und 75%-Quartil (Q_{75}) der Datenverteilung entsprechen. Das entspricht dem Bereich, in dem 50% der Daten liegen. Die rote Linie in der Box beschreibt den Median der Datenverteilung. Der Wertebereich zwischen Q_{25} und Q_{75} bildet den *Interquartilsabstand* (en: *interquartile range*, IQR), welcher zur Analyse der Streuung verwendet wird. Die horizontale Linien außerhalb der Box, Whisker genannt, sind hier gemäß Velleman und Hoaglin [1981] auf einen maximalen Abstand zur Box von $1.5 \cdot \text{IQR}$ beschränkt. Datenpunkte, deren Werte außerhalb des Bereichs von $Q_{25} - 1.5 \cdot \text{IQR}$ bis $Q_{75} + 1.5 \cdot \text{IQR}$ liegen, werden als Ausreißer angesehen; diese werden als rote Kreuze dargestellt (siehe Abbildung 5.3). Sind jedoch keine Ausreißer oberhalb bzw. unterhalb des oben genannten Wertebereiches in den Daten vorhanden, liegen die Whisker an der Stelle des maximalen bzw. minimalen Wertes (siehe Abbildung 5.3).

Perzentil-Plot. Eine andere Art der Darstellung von Verteilungen auf Basis von bestimmten Quantilen ist der sogenannter *Perzentil-Plot*. Um einen Perzentil-Plot aus einer beliebigen gestreuten Datenstichprobe der Größe η zu erstellen, werden zunächst deren Werte x aufsteigend sortiert. Dann wird das empirische q -Quantil von x_1, \dots, x_η wie folgt berechnet [Henze, 2013]:

$$x_q = \begin{cases} x_{(\lfloor \eta \cdot q + 1 \rfloor)} & \text{falls } (\eta \cdot q) \notin \mathbb{N} \\ \frac{1}{2} \cdot (x_{(\eta \cdot q)} + x_{(\eta \cdot q + 1)}) & \text{falls } (\eta \cdot q) \in \mathbb{N} \end{cases}, \quad (5.5)$$

wobei $\lfloor * \rfloor$ einer Abrundung auf die nächst liegende ganze Zahl entspricht. Weiterhin tragen bestimmte Quantile eigene Namen, so wie z.B. das untere (Q_{25}) und obere Quartil (Q_{75}) aus dem vorherigen Abschnitt. Als Perzentile werden z.B. Quantile im Bereich $q \in [0.01, \dots, 0.99]$ in Schritten von $\Delta q = 0.01$, bezeichnet, die den Wertebereich der Stichprobe in 100 gleich große Intervalle aufteilen. Beim Perzentil-Plot werden die Perzentile in Prozent auf der Ordinate und die zugehörigen empirischen q -Quantile von x_1, \dots, x_η (x_q) auf der Abszisse eingetragen. Das Ergebnis entspricht etwa der relativen Summenhäufigkeit der Werte der Datenstichprobe (siehe Abbildung 5.4). Die Formel aus Gleichung 5.5 bewirkt, dass mindestens $q \cdot 100\%$ der Stichprobenwerte kleiner oder gleich x_q und mindestens $(1 - q) \cdot 100\%$ der Stichprobenwerte größer x_q sind [Henze, 2013]. So lässt sich aus dem Perzentil-Plot in Abbildung 5.4 ablesen, dass 29% der Stichprobenwerte aus Abbildung 5.4 kleiner oder gleich 0 und 71% größer 0 sind. Außerdem lässt sich aus dem Perzentil-Plot der Median der Daten aus dem Schnittpunkt der Kennlinie mit dem 50% Perzentil und der Projektion des Schnittpunktes auf die Abszisse ablesen: der Median liegt in Perzentil-Plot aus Abbildung 5.4 etwa bei dem Wert 7.

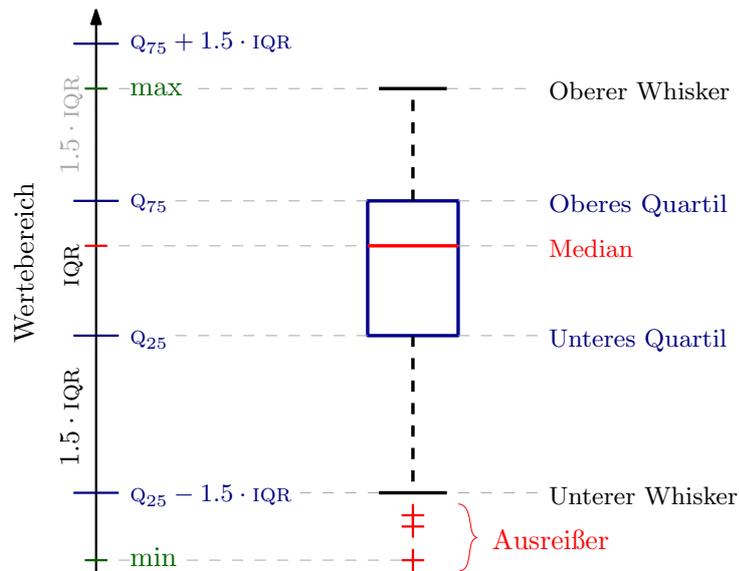


Abbildung 5.3: Aufbau von Box-Plot Diagramm (IQR steht für Interquartilsabstand).

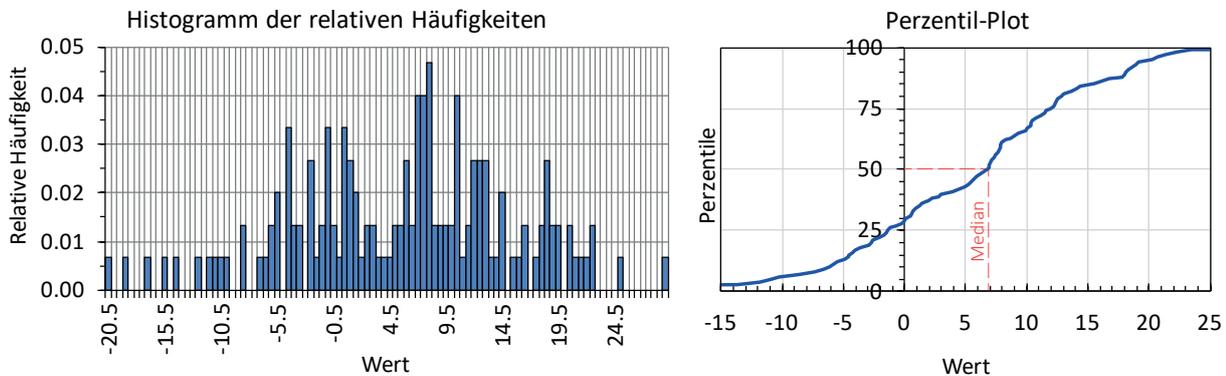


Abbildung 5.4: Aufbau des Perzentil-Plots. Die Abbildung zeigt das Histogramm der relativen Häufigkeiten (links) für eine zufällige Datenmenge und den zugehörigen Perzentil-Plot (rechts). Die 150 Werte der gestreuten Daten sind normalverteilt mit Mittelwert $\mu = 5$ und Standardabweichung $\sigma = 10$ im Bereich von -21 bis 29 .

ROC-Kurve. Eine *Grenzwertoptimierungskurve* (en: *Receiver Operating Characteristic*), kurz ROC-Kurve, ist eine grafische Darstellung zur Analyse der Qualität eines binären Klassifikationsproblems für verschiedene Parameterwerte. Dabei wird für jeden untersuchten Parameter der Wert *True-Positive-Rate* (TPR) und *False-Positive-Rate* (FPR) ermittelt, wobei für TPR und FPR gilt:

$$TPR = \frac{\#TP}{\#TP + \#FN} \quad \text{und} \quad FPR = \frac{\#FP}{\#FP + \#TN}. \quad (5.6)$$

Dabei entspricht die TPR der Vollständigkeit der Vordergrundklasse bei einem binären Klassifikationsproblem. Die TPR wird manchmal auch als Detektionsrate und FPR als Fehlerrate bezeichnet. Die ROC-Kurve wird gebildet, indem die Werte von TPR in Abhängigkeit von FPR für verschiedene Parameterwerte aufgetragen werden. In den Anwendungen, in denen eine hohe TP-Rate und eine niedrige FP-Rate erforderlich ist, kann die ROC-Kurve zur Ermittlung einer optimalen Parametereinstellung eingesetzt werden. Dabei entspricht der Wert des Parameters, dessen Punkt auf der gebildeten Kurve am nächsten zum Punkt mit $TPR = 1$ und $FPR = 0$ liegt,

einem optimalen Parameterwert für das vorliegende binäre Klassifikationsproblem [Davis und Goadrich, 2006]. Die ROC-Kurve wird im Rahmen dieser Arbeit verwendet, um einen möglichst guten Schwellwert zur Prädiktion von NT zu ermitteln.

Regressionsanalyse und Bestimmtheitsmaß. Die Regressionsanalyse wird verwendet, um die Abhängigkeiten zwischen Variablen zu modellieren und über einen funktionalen Zusammenhang beschreiben zu können. Im Rahmen dieser Arbeit wird eine einfache lineare Regression angewendet, die von einem linearen Zusammenhang zwischen einer Eingangs- und einer Ausgangsvariablen ausgeht. Es wird davon ausgegangen, dass die Qualität einer Adaption (abhängige Ausgangsvariable) von der Diskrepanz zwischen zwei Domänen abhängig ist, welche durch ein Distanzmaß (unabhängige Eingangsvariable) beschrieben wird. Diese Abhängigkeit zwischen zwei Variablen wird im Rahmen der Analyse durch eine Regressionsgerade modelliert. Ausgehend von der ermittelten Regressionsgeraden wird der Grad der zu analysierenden Abhängigkeit mit Hilfe des Bestimmtheitsmaßes R^2 festgestellt. Das Bestimmtheitsmaß R^2 ($R^2 \in [0..1]$) gibt an, wie groß der Anteil der Streuung in den Daten ist, der durch ein vorliegendes Regressionsmodell erklärt werden kann: je größer der Wert desto besser. Es wird in Prozent angegeben. Das Bestimmtheitsmaß R^2 steht im Zusammenhang mit dem empirischen Korrelationskoeffizienten nach Bravais-Pearson r [Fahrmeir et al., 2016]: $r^2 = R^2$.

5.4 Evaluierung der Domänenadaptation

In dieser Arbeit liegt in jedem Test zur DA ein Quell- und ein Zieldatensatz vor. Im Rahmen der experimentellen Untersuchungen der DA werden die Genauigkeitsmaße auf Basis der Konfusionsmatrizen für vier verschiedene Varianten ermittelt. In der ersten Variante V_{SS} wird der Klassifikator (LR) auf Basis der Trainingsdaten aus der Quelldomäne angelernt und auf den nicht zum Training genutzten Daten der Quelldomäne evaluiert. Die Variante V_{ST} erhält man, indem der Klassifikator, der auf den Trainingsdaten aus der Quelldomäne angelernt wurde, auf den Daten der Zieldomäne ohne DA evaluiert wird. Damit entspricht diese Variante dem traditionellen überwachten maschinellen Lernen ohne DA. Bei der Variante V_{TT} wird der Klassifikator unter Einbeziehen von Labels aus der Referenz aus der Zieldomäne trainiert und auf den nicht zum Training genutzten Daten der Zieldomäne evaluiert. Die Ergebnisse in dieser Variante werden als obere Schranke für die auf Daten der Zieldomäne mit dem Basisklassifikator erreichbare Genauigkeit interpretiert. Schließlich wird in der Variante V_{DA} der Basisklassifikator anhand von Trainingsdaten der Quelldomäne angelernt und auf den gesamten Daten der Zieldomäne nach der DA evaluiert. Die vorhandenen Referenzdaten werden im Verlauf der DA in der Variante V_{DA} gemäß den Annahmen dieser Arbeit dem Klassifikator ausschließlich zum Trainieren an der Quelldomäne zugänglich gemacht. Zur quantitativen Auswertung des in der jeweiligen Variante zu evaluierenden Klassifikators werden die Gesamtgenauigkeit (OA), sowie die klassenspezifischen Genauigkeitsmaße Korrektheit ($Corr$), Vollständigkeit ($Comp$) und $F1$ -Maß ($F1$) ermittelt.

Auf Basis der in der jeweiligen Variante ermittelten Gesamtgenauigkeiten werden anschließend zwei weitere Qualitätsmaße für die DA definiert. Das Qualitätsmaß ΔOA_{DA} zur Beurteilung der Güte einer Adaption wird aus Differenz der Gesamtgenauigkeiten der Varianten V_{DA} und V_{ST} abgeleitet:

$$\begin{aligned}\Delta OA_{DA} &= OA_{DA} - OA_{ST} \quad \text{mit} & (5.7) \\ \Delta OA_{DA} &\geq 0 \quad \text{positiver Transfer} \\ \Delta OA_{DA} &< 0 \quad \text{negativer Transfer.}\end{aligned}$$

Dabei entspricht OA_{ST} und OA_{DA} der Gesamtgenauigkeit, die für den Klassifikator in der Variante V_{ST} bzw. in der Variante V_{DA} nach der DA auf Daten der Zieldomäne erreicht wurde. Das Genauigkeitsmaß ΔOA_{DA} erlaubt eine einfache Beurteilung von NT. Ein Wert von ΔOA_{DA} kleiner als Null ($\Delta OA_{DA} < 0$) zeigt eine Verschlechterung der Klassifikationsgenauigkeit nach der DA, es fand also NT statt; andernfalls ($\Delta OA_{DA} \geq 0$) war der Wissenstransfer positiv. Damit signalisiert dieser Wert entweder einen Verlust oder einen Gewinn in der Klassifikationsgenauigkeit aufgrund der Anwendung von der DA. Das zweite Qualitätsmaß ΔOA_{TD} wird wie folgt definiert:

$$\Delta OA_{TD} = OA_{TT} - OA_{DA}, \quad (5.8)$$

wobei OA_{TT} der Gesamtgenauigkeit entspricht, die für den Klassifikator in der Variante V_{TT} auf Daten der Zieldomäne erreicht wurde. Somit misst ΔOA_{TD} den Verlust in der Gesamtgenauigkeit nach DA aufgrund den fehlenden Trainingsdaten in der Zieldomäne (Variante V_{DA}) im Vergleich zu dem Ergebnis der oberen Schranke (Variante V_{TT}). Dabei gilt: je kleiner der Wert ΔOA_{TD} , desto besser. Demzufolge entspricht ein negativer Wert von ΔOA_{TD} einer Verbesserung der Klassifikationsgenauigkeit auf Daten der Zieldomäne gegenüber der Variante V_{TT} , in der der Klassifikator an gelabelten Daten ebendieser Zieldomäne angelernet wurde.

5.5 Merkmale

In diesem Kapitel werden die in den Experimenten genutzten Merkmale beschrieben.

Extrahierte Merkmale. Das vorhandene Bildmaterial für den jeweiligen Testgebiet wurde in Kapitel 5.1 beschrieben. Aus diesen Daten werden im Vorverarbeitungsschritt im Rahmen dieser Arbeit unterschiedliche Merkmale extrahiert. Dabei erfolgt die Extraktion in einem Durchlauf für das gesamte Testgebiet. Zur Evaluierung wird gemäß der Anforderungen an die DA jeweils der gleiche Satz von Merkmalen für jedes Testgebiet extrahiert. Die extrahierten Merkmale können in folgende vier Gruppen aufgliedert werden: spektrale, texturelle, kontextuelle und 3D-Merkmale. Eine Übersicht über die Merkmale ist in Tabelle 5.3 gegeben. Merkmale der ersten Gruppe, spektrale Merkmale, entsprechen den originalen Spektralwerten der jeweiligen Farbkanäle Rot R, Grün G oder Nahes Infrarot NIR bzw. lassen sich direkt aus diesen berechnen, wie z.B. NDVI, Farbton, Sättigung oder Intensität. Die Werte der 3D-Merkmalen beschreiben die Höhe der zugehörigen Pixel in der Aufnahme relativ zu einer Bezugshöhe. Sie können z.B.

als DOM, DGM oder nDOM erfasst werden, wobei ein normalisiertes digitales Oberflächenmodell nDOM die Höhe der Objekte über den Grund beschreibt. Die textuellen Merkmale beschreiben charakteristische Muster in einer lokalen Region. Eine Analyse der Textur wird häufig auf Basis der Co-Occurrence Matrix von Haralick [Haralick et al., 1973] durchgeführt. Aus dieser Matrix lassen sich die Texturmerkmale, wie z.B. Homogenität, Kontrast, Entropie oder Energie berechnen. Die kontextuellen Merkmale beschreiben dagegen nur die lokale Bildstruktur. Die Extraktion von Kontextmerkmalen kann auf Basis aller bereits genannten Merkmalen stattfinden. Die Werkzeuge zur Ermittlung der kontextuellen Merkmale in 2D sind: Gauß-Filter, Mittelwert bzw. Varianz mit einer vorgegebenen Fenstergröße. Zusätzlich werden für die Intensität, das DOM und das nDOM der Gradientenbetrag und Gradientenrichtung als Merkmale extrahiert.

Tabelle 5.3: Menge aller extrahierten Merkmale aufgeteilt nach Gruppen. Englische Bezeichnungen der Merkmale (in Klammern) werden bei der Analyse deren Wichtigkeit in Abbildung 5.5 verwendet.

Gruppe	Grundlage	Merkmal/Bezeichnung
Spektral	Spektralwert: Rot Spektralwert: Grün Spektralwert: Nahes Infrarot	R G NIR Farbton (Hue) Sättigung (Saturation) Intensität (Intensity) NDVI
3D	DOM	DOM (DSM) nDOM (nDSM)
Textur	Grauwertmatrix (GLCM)	Haralick Homogenität (Haralick_Homogeneity) Haralick Kontrast (Haralick_Contrast) Haralick Entropie (Haralick_Entropy) Haralick Energie (Haralick_Energy)
Kontext	Spektralwert: Rot Spektralwert: Grün Spektralwert: Nahes Infrarot Sättigung Intensität NDVI DOM nDOM	Mittelwert (Mean) Gauß-Filter (Gauss) Varianz (Variance)
	Intensität DOM nDOM	Gradienten-Betrag (Gradient_Magnitude) Gradienten-Richtung (Gradient_Orientation)

Auswahl diskriminativer Merkmale. In diesem Abschnitt wird die Vorgehensweise bei der Auswahl der Merkmale zur Evaluierung der DA beschrieben. Das Ergebnis der DA hängt stark von den verwendeten Merkmalen ab. Sinnvoll ausgewählte Merkmale können zum einen die Klassifikationsgenauigkeit des initialen Klassifikators verbessern und zu einer besseren Ausgangslage für die DA verhelfen. Zum anderen können diskriminative Merkmale für die Genauigkeit der Zuwei-

sung von Semi-Labels während der Adaption von Vorteil sein. Der intuitive Gedanke, möglichst viele Merkmale einzubeziehen, um durch zusätzliche Informationen die Klassifikationsgenauigkeit zu erhöhen, stimmt nur bedingt. Das Hughes-Phänomen [Hughes, 1968] besagt, dass die Erweiterung des Merkmalsraumes bei konstant bleibendem Umfang der Trainingsbeispiele nur bis zu einem bestimmten Grad der Erweiterung zu einer Verbesserung der Klassifikationsgenauigkeit führt, danach fällt die Genauigkeit wieder ab. Es wird in dieser Arbeit jedoch angestrebt, die Menge der Trainingsdaten möglichst klein zu halten. Außerdem erhöht eine unkontrollierte Ergänzung durch neue Merkmale die Dimension des Merkmalsraumes und beeinträchtigt die Rechenzeit des Algorithmus. Trotzdem kann der Klassifikationsfehler durch eine geeignete Auswahl von diskriminativen, unkorrelierten Merkmalen klein gehalten werden.

Die Auswahl der Merkmale in dieser Arbeit erfolgt auf Basis eines Wichtigkeitsmaßes von RF [Breiman, 2001]. Mit Hilfe des Wichtigkeitsmaßes wird der Einfluss der Merkmale auf die Klassifikation ausgewertet. Zu diesem Zweck kommt eine relativ kleine Teilmenge der Trainingsbeispiele zum Einsatz, die nicht zum tatsächlichen Training eingesetzt wird. Die Werte des zu analysierenden Merkmals werden in dieser Teilmenge zufällig vertauscht. Die Wichtigkeit eines Merkmals ergibt sich dann aus der Differenz zwischen der originalen und der nach dem Vertauschen resultierenden Genauigkeit: je größer die Differenz, desto höher ist der Einfluss des untersuchten Merkmals und desto größer ist seine Wichtigkeit. Die Auswahl der Merkmale erfolgte hier auf Basis der Analyse von 50 Merkmalen (siehe Abbildung 5.4). Die Untersuchung fand auf dem Datensatz $\mathcal{D}_{\text{DT}}^{\text{Pot}}$ statt, der 12 Bildkacheln aus dem Testgebiet *Potsdam* beinhaltet (siehe Tabelle 5.4). Es fanden also 12 einzelne Experimente statt, in denen das Wichtigkeitsmaß für den gleichen Satz von Merkmalen separat pro Kachel ausgewertet wurde. Die Verwendung der Daten nur aus einem der Testgebiete soll eine Annäherung an reale Bedingungen im Kontext der Evaluierung des entwickelten Ansatzes zur DA abbilden. So stünden im Falle einer realen Anwendung des Ansatzes die gelabelten Daten zur Untersuchung der Merkmale nur für den Trainingsdatensatz (Quelldomäne) zur Verfügung. Die in den Experimenten ermittelten Wichtigkeiten wurden weiterhin pro Merkmal gemittelt und nach der Wichtigkeit absteigend sortiert. Die Ergebnisse sind in Abbildung 5.5 präsentiert. Aus der gesamten Menge der Merkmale wurde eine moderate Anzahl von 10 Merkmalen zur Evaluierung ausgewählt, deren Wichtigkeit größer oder gleich 2% beträgt.

Tabelle 5.4: Übersicht über den Datensatz zur Untersuchung der diskriminativen Merkmale. Der Datensatz beinhaltet 12 von 38 Kacheln aus dem Testgebiet Potsdam, die hier mittels der numerischen Kodierung aus Abbildung 5.2b aufgelistet sind.

Datensatz	#Kacheln	Testgebiet	Kachel-Nrn.
$\mathcal{D}_{\text{DT}}^{\text{Pot}}$	12	Potsdam	02_11, 03_10, 03_12, 04_11, 05_10, 05_12, 06_07, 06_09, 06_11, 07_08, 07_10, 07_12

Beschreibung der ausgewählten Merkmale. Eine Übersicht über die ausgewählten Merkmale ist in der Tabelle 5.5 ersichtlich. Zunächst wird ein *normalisiertes digitales Oberflächenmodell* nDOM gewählt, welches den Höhen der Objekte über Grund entspricht. Dieses Merkmal weist mit Abstand den größten Wert des Wichtigkeitsmaßes auf. Zu dessen Bestimmung ist ein *digitales Geländemodell* DGM notwendig. Da das DGM nicht vorhanden ist, muss es aus dem DOM

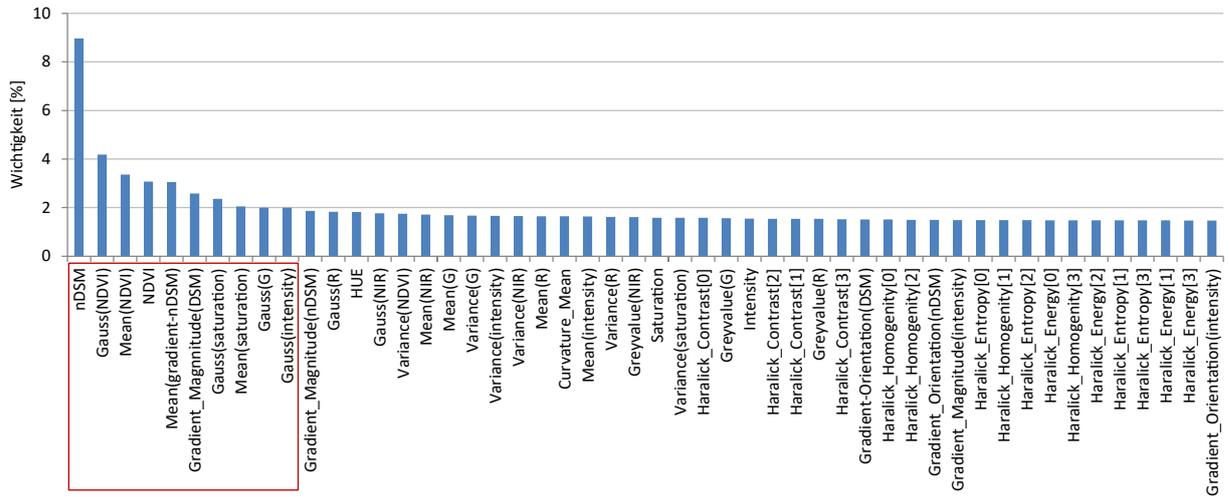


Abbildung 5.5: Wichtigkeit der Merkmale in Prozent. Die Werte sind in absteigender Reihenfolge sortiert. Zur Evaluierung ausgewählte Merkmale sind durch das rote Rechteck markiert. Für die Merkmale wurden die englischen Bezeichnungen aus der Programmausgabe verwendet (vgl. mit Tabelle 5.3).

Tabelle 5.5: Ausgewählte Merkmale in abfallender Reihenfolge der Wichtigkeit (vgl. mit Abbildung 5.5).

Ausgewählte Merkmale	
1.	nDOM
2.	NDVI nach Faltung mit Gauß-Filter
3.	NDVI nach Faltung mit Mittelwertfilter
4.	NDVI
5.	Mittelwert des Gradientenbetrages des nDOM
6.	Betrag des Gradienten des DOM
7.	Sättigung nach Faltung mit Gauß-Filter
8.	Sättigung nach Faltung mit Mittelwertfilter
9.	Spektralwert Grün nach Faltung mit Gauß-Filter
10.	Intensität nach Faltung mit Gauß-Filter

generiert werden. Dafür kommt oft die Methode aus [Weidner und Förstner, 1995] auf Basis eines *morphologischen Opening* zum Einsatz, mit der alle Strukturen kleiner als ein Strukturelement herausgefiltert werden, um ein DGM zu erhalten. Es entstehen dadurch allerdings bedingt durch die Größe und Form des Strukturelementes Artefakte, die das DGM und somit das nDOM stark verfälschen können. Um das DGM-Ergebnis zu verbessern, wird in dieser Arbeit vorgeschlagen, zusätzlich einen Medianfilter im Vorfeld der Opening-Operationen anzuwenden und eine Glättung mit dem Gaußfilter am Ende durchzuführen, um die Artefakte nach den morphologischen Operationen herauszufiltern.

Der gesamte Ablauf der vorgeschlagenen Extraktion inklusive Fenstergrößen der verwendeten Filter ist in Tabelle 5.6 vorgestellt. Das Algorithmus braucht das DOM selbst sowie die GSD, Parameter θ^{high} , θ^{low} und ein Schwellwert τ_{DGM} (in $[m]$) als Eingangsdaten. Die Parameter θ^{high} und θ^{low} steuern in erster Linie die Größen der jeweiligen verwendeten Filtermasken, die sich je nach Testgebiet unterscheiden. Der Parameter θ^{high} wird an das größte künstliche zu eliminie-

Tabelle 5.6: Ablauf der Extraktion von DGM aus DOM.**Algorithmus:** Extraktion von DGM aus DOMEingabe: DOM, GSD $[m]$, θ^{high} $[m]$, θ^{low} $[m]$, τ_{DGM} $[m]$

Ausgabe: DGM

Filtergrößen:

$$W_{SE}^{high} = 2 \cdot \lfloor \frac{1}{2} \cdot \frac{\theta^{high}}{GSD} \rfloor + 1, \text{ wobei } 2 \cdot \lfloor \frac{1}{2} * \rfloor + 1 \text{ eine ungerade Filtergröße bewirkt}$$

$$W_{SE}^{low} = 2 \cdot \lfloor \frac{1}{2} \cdot \frac{\theta^{low}}{GSD} \rfloor + 1$$

$$W_{Med} = 2 \cdot \lfloor \frac{1}{2} \cdot \frac{W_{SE}^{high}}{10} \rfloor + 1$$

$$W_{Gauss} = 2 \cdot (2 \cdot \sigma_{DGM}) + 1 \quad \text{mit} \quad \sigma_{DGM} = 2 \cdot \lfloor \frac{1}{2} \cdot \frac{W_{SE}^{high} - 1}{2.4} \rfloor + 1$$

Vorgehensweise:

1. Anwendung eines Medianfilters der Größe W_{Med} auf das DOM

$$DOM_{Med} = \text{Median}(\text{DOM}, W_{Med})$$

2. Morphologisches Opening mit einem quadratischen Strukturelement der Größe W_{SE}^{low} und W_{SE}^{high}

$$DGM_{Open}^{low} = \text{Opening}(\text{DOM}_{Med}, W_{SE}^{low})$$

$$DGM_{Open}^{high} = \text{Opening}(\text{DOM}_{Med}, W_{SE}^{high})$$

3. Kombination der DGM-Werte für jeden Pixel n des DGM-Bildes

$$DGM_{Comb}(n) = \begin{cases} DGM_{Open}^{low}(n) & \text{falls } (DGM_{Open}^{low}(n) - DGM_{Open}^{high}(n)) \leq \tau_{DGM} \\ DGM_{Open}^{high}(n) & \text{falls } (DGM_{Open}^{low}(n) - DGM_{Open}^{high}(n)) > \tau_{DGM} \end{cases}$$

4. Faltung des Ergebnisses mit dem Gauß-Filter der Größe W_{Gauss}

$$DGM = \text{Gauss}(DGM_{Comb}, W_{Gauss}(\sigma_{DGM}))$$

rende Objekt in DOM angepasst, welches in DGM nicht enthalten werden soll. θ^{high} wird für den Testgebiet *Vaihingen* auf 40m, für *Potsdam* auf 80m und für *Buxtehude, Hannover, Nienburg* jeweils auf 120m gesetzt, wobei der Wert sich aus der maximalen Größe der zusammenhängender Gebäudeblöcke in dem jeweiligen Testgebiet ergibt. Der Wert von θ^{low} beschreibt dagegen die minimale Größe der Objekte, die zu eliminieren sind. Für θ^{low} wird hier für alle Testgebiete $\theta^{low} = 1m$ angenommen. Im ersten Schritt des Algorithmus aus Tabelle 5.6 wird ein Medianfilter auf das DOM angewendet, um Ausreißer zu eliminieren. Die Annahme über die Größe des Filters orientiert sich nach θ^{high} (siehe Tabelle 5.6), womit sich die Störungen bis zu einer Größe von $\frac{1}{10} \cdot \theta^{high}$ (in $[m]$) beseitigen lassen. Das anschließende Opening mit unterschiedlich großen Filtermasken in Abhängigkeit von θ^{high} und θ^{low} resultiert vorerst in zwei unterschiedlichen Höhenmodellen im zweiten Schritt des Algorithmus. Das Opening mit θ^{low} dient dabei zur Korrektur des Ergebnisses nach dem Opening mit θ^{high} im nächsten Schritt. Die Kombination der beiden Ergebnisse im Schritt 3 soll die Genauigkeit des resultierenden DGM verbessern. Die Idee dahinter ist folgende: falls die Differenz ($DGM_{Open}^{low}(n) - DGM_{Open}^{high}(n)$) größer als Schwellwert τ_{DGM} (hier $\tau_{DGM} = 1m$) ist, dann handelt es sich wahrscheinlich um eine große Struktur, die eliminiert werden soll (Zuweisungswert: $DGM_{Open}^{high}(n)$); falls jedoch die Differenz kleiner oder gleich $1m$ ist, dann wird von einer zu starken Filterung beim Opening mit dem größeren Strukturelement ausgegangen, die korrigiert werden soll (Zuweisungswert: $DGM_{Open}^{low}(n)$). Eine anschließende Filterung mit dem Gauß-Filter glättet die Sprungstellen in dem kombinierten DGM und reduziert die restlichen Artefakte der morphologischen Operation. Die Größe der Standardabweichung

σ_{DGM} orientiert sich dabei an θ^{high} (siehe Tabelle 5.6). Es lassen sich damit kleine Störungen bis zu einer Größe von etwa $\frac{1}{8} \cdot \theta^{\text{high}}$ (in [m]) reduzieren. Nachdem das DGM generiert wurde, erfolgt die Berechnung von nDOM:

$$n\text{DOM} = \text{DOM} - \text{DGM}. \quad (5.9)$$

Es wurden außerdem zwei Kontextmerkmale auf Basis des DOM bzw. nDOM ausgewählt: Betrag des Gradienten des DOM und der Mittelwert des Gradientenbetrages des nDOM. Bei der Berechnung des Gradientenbetrages erfolgt zu Beginn eine Faltung des DOM mit dem Gauß-Filter mit der Standardabweichung $\sigma_{\text{Kontext}} = 2$ (Filtergröße: $W_G = 2 \cdot 3 \cdot \sigma_{\text{Kontext}} + 1$). Dann werden, um den Gradient zu bestimmen, zwei partiellen Ableitungen des gefilterten Ergebnisses I (je eine Ableitung pro Dimension des Bildes) ermittelt und anschließend der Gradientenbetrag für jedes Pixel ausgerechnet:

$$\text{Gradient:} \quad \nabla I(x, y) = \begin{pmatrix} I_x \\ I_y \end{pmatrix} = \begin{pmatrix} \frac{\partial I}{\partial x} \\ \frac{\partial I}{\partial y} \end{pmatrix} \quad (5.10)$$

$$\text{Gradientenbetrag:} \quad |\nabla I(x, y)| = \sqrt{I_x^2 + I_y^2}. \quad (5.11)$$

Zur Berechnung des Mittelwertes des Gradientenbetrages des nDOM wird zunächst der Gradientenbetrag des nDOM analog zu der Beschreibung oben ermittelt. Anschließend findet zur Berechnung des Mittelwertes eine Faltung mit dem Mittelwertfilter der Größe $W_M = 13$ statt, um kleine Artefakte und Rauschen im neuen Merkmal zu reduzieren.

Es folgen drei Merkmale auf Grundlage des NDVI: der NDVI selbst, sowie seine Faltung mit dem Gauß-Filter mit der Standardabweichung $\sigma_{\text{Kontext}} = 5$ (Filtergröße: $W_G = 2 \cdot 3 \cdot \sigma_{\text{Kontext}} + 1$) bzw. mit dem Mittelwertfilter der Größe $W_M = 13$. Der *Normalised Difference Vegetation Index* (NDVI) ist dabei ein Indikator für die Vegetation. Seine Berechnung basiert auf der Kombination der Werte der Kanäle NIR und R, da das Licht im NIR-Bereich von Vegetation stark reflektiert wird, während der Anteil im roten Teil des Spektrums absorbiert wird [Strunz et al., 2017]:

$$\text{NDVI} = \frac{\text{NIR} - \text{R}}{\text{NIR} + \text{R}}. \quad (5.12)$$

Es ergibt sich damit ein Wertebereich von -1 bis 1 , wobei hohe NDVI-Werte nahe 1 auf vitale Vegetation hindeuten.

Eine weitere Gruppe der ausgewählten Merkmale bilden vier Kontextmerkmale auf Basis von Intensität, Sättigung und dem grünen Farbkanal: Faltung der Intensität, der Sättigung und des grünen Farbkanals mit einem Gauß-Filter mit der Standardabweichung $\sigma_{\text{Kontext}} = 5$ (Filtergröße: $W_G = 2 \cdot 3 \cdot \sigma_{\text{Kontext}} + 1$), sowie Faltung der Sättigung mit dem Mittelwertfilter der Größe $W_M = 13$. Die Bestimmung der Intensität und Sättigung findet auf Grundlage der Bänder NIR-R-G für alle Testgebiete statt, da der Blaukanal in den Bilddaten fehlt bzw. nicht genutzt wird (siehe Abschnitt 5.1). Die Berechnung von Intensität und Sättigung erfolgt analog zu Beschrei-

bung aus [Burger und Burge, 2005]:

$$\text{Intensität} \quad f_I = \max(g_{NIR}, g_R, g_G), \quad (5.13)$$

$$\text{Sättigung} \quad f_S = \begin{cases} \frac{f_I - \min(g_{NIR}, g_R, g_G)}{f_I} & \text{falls } f_I > 0 \\ 0 & \text{sonst} \end{cases}. \quad (5.14)$$

Merkmalsraum. Die Extraktion der Merkmale erfolgt in einem Durchlauf für alle Kacheln des jeweiligen Testgebietes. Die entsprechenden Merkmale werden anschließend linear in den Bereich $[0, 1]$ abgebildet. Dabei erfolgt die Skalierung des jeweiligen Merkmals mit 1%- bzw. 99%-Quantil über das gesamte Testgebiet, d.h. dass jeweils ein Prozent der Pixel mit den kleinsten bzw. größten Werten auf 0 bzw. auf 1 gesetzt wird. Dadurch wird der Einfluss von Ausreißern mit Extremwerten in den Daten gemildert. Gemäß den Anforderungen der DA soll der Merkmalsraum für Quell- und die Zieldomäne gleich sein. Aus diesem Grund wird zur Evaluierung der DA jeweils der gleiche Satz von 10 ausgewählten Merkmalen für alle Testgebiete extrahiert. Weiterhin findet in den Experimenten zu DA eine polynomiale Erweiterung des Merkmalsraumes $\Phi(\mathbf{x})$ vom Grad 2 statt, um nicht lineare Entscheidungsgrenzen zu erhalten (siehe Kapitel 2.1.1). Damit entsteht im Endeffekt ein Merkmalsraum der Dimension 66.

6 Experimente

In diesem Kapitel wird der entwickelte Ansatz zur Domänenadaption anhand einer experimentellen Untersuchung mit realen Daten evaluiert. In Kapitel 6.1 werden zunächst die optimalen Einstellungen für den entwickelten Ansatz zur DA untersucht, die im Weiteren bei der Evaluierung des Ansatzes eingesetzt werden. Das Kapitel 6.2 beschäftigt sich mit der Analyse der Prädiktion von negativem Transfer mit der vorgeschlagenen Methode auf Basis der MMD Metrik. Die anschließenden Kapitel 6.3 und 6.4 untersuchen die Leistungsfähigkeit des entwickelten Ansatzes zur Adaption des Klassifikators auf die Zieldomäne sowie bei der Prädiktion von negativem Transfer. In Kapitel 6.5 wird die entwickelte Methode zur DA mit einem generativen Ansatz verglichen.

6.1 Parameter

Zur DA mit dem entwickelten Ansatz müssen verschiedene Parameter vom Nutzer gesetzt werden (siehe Tabelle 4.2). Diese Parameter haben einen Einfluss auf das Ergebnis und werden im Folgenden untersucht. Die zu untersuchenden Parameter können in zwei Gruppen aufgeteilt werden: Parameter der ersten Gruppe beeinflussen in erster Linie den initialen Klassifikator, während Parameter der zweiten Gruppe über die Kostenfunktion einen direkten Einfluss auf die DA haben. Als Ergebnis der Untersuchung werden die optimierten Parametereinstellungen ermittelt. Die Ermittlung beginnt ausgehend von einer Reihe initial gesetzter Parameterwerte. Die Initialwerte für alle 9 zu untersuchenden Parameter sind in der Tabelle 6.1 aufgelistet.

Tabelle 6.1: Initiale Einstellungen der zu untersuchenden Parameter des Modells.

RW (#Trainingsbeispiele)	Initiale Parametereinstellungen							
	σ_0	σ_{DA}	ρ	k	γ	i_{max}	$g_{S,max}$	$g_{T,max}$
29 (ca. 17000)	1.5	5.0	30	19	0.6	200	1.5	0.9

6.1.1 Parameter des Klassifikators

6.1.1.1 Zielsetzung

Die erste Gruppe der Parameter des Klassifikators setzt sich aus zwei Parametern zusammen: der Anzahl der Trainingsbeispiele in \overline{TD} in Abhängigkeit von dem Parameter RW für die Rasterweite und dem Parameter σ_0 zur Steuerung der Regularisierung während des initialen Trainings des

Klassifikators. Der Einfluss dieser Parameter soll hier in einer Reihe von Experimenten untersucht werden. Im Rahmen der Untersuchung sollen die optimalen Einstellungen der Parameter des initialen Klassifikators im Rahmen der DA ermittelt werden. Die Anzahl der Experimente zur Ermittlung einer optimalen Einstellung für den jeweiligen Parameter variiert in Abhängigkeit von der Anzahl der untersuchten Einstellungsmöglichkeiten. Im Rahmen eines Experiments werden mehrere Tests durchgeführt. Die Auswertung der Ergebnisse für die jeweilige Parametereinstellung erfolgt auf Basis der für die Einstellung erzielten Gesamtgenauigkeiten OA in den Tests der entsprechenden Testreihe bzw. des Experiments. Eine möglichst gute Qualität des initialen Trainings des Klassifikators stellt eine gute Ausgangslage für die darauf folgende DA dar. Die Rechenzeit ist ein wichtiges Kriterium bei der Durchführung der Experimente und wird bei der Auswahl der geeigneten Parametereinstellungen mitberücksichtigt. Das Ziel der Experimente ist hier also, die optimalen Parameter auszuwählen, die einen Kompromiss zwischen der Genauigkeit der Klassifikation und dem Zeitaufwand (Rechenzeit) darstellen.

6.1.1.2 Durchführung der Experimente

Vorgehensweise zur Bestimmung der Parametereinstellungen. Die Bestimmung der optimalen Werte der Parameter erfolgt auf Basis einer empirischen Untersuchung mit dem *Greedy Search* Ansatz [Cormen et al., 2009]. Greedy Search ist ein heuristischer Lösungsansatz, der schrittweise eine lokal optimale Wahl der Parameter durchführt, um ein globales Optimum zu finden. Dabei kann die Reihenfolge bei der Wahl der Parameter einen Einfluss auf das Endergebnis haben. Damit führt dieser Ansatz in der Realität nicht immer zu einer global optimalen Lösung des Problems, aber er liefert immerhin eine lokal optimale Lösung in angemessener Zeit. Es wird dabei wie folgt vorgegangen: Ausgehend von initial gesetzten Parameterwerten und Kriterien zur Bewertung einer Parametereinstellung wird einer der Parameter in der aktuellen Untersuchung variiert, wobei die anderen Parameter fixiert bleiben. Als Ergebnis der Untersuchung wird ein lokal optimaler Wert ausgewählt, welcher den Bewertungskriterien entspricht. Danach wird die Einstellung für den untersuchten Parameter durch den ermittelten lokal optimalen Wert ersetzt und die Prozedur setzt sich mit einem der restlichen Parameter fort.

Datensatz. Die experimentelle Untersuchung erfolgt auf dem *Potsdam* Datensatz $\mathcal{Q}_{U_1}^{Pot}$. Dieser besteht aus 19 von 38 Bildkacheln des Testgebietes Potsdam, die in der Tabelle 6.2 aufgelistet sind. Die Bildkacheln wurden in Schachbrettmuster (vgl. die Nummern mit denen aus Abbildung 5.2b) ausgewählt, um das ganze Testgebiet erfassen zu können und gleichzeitig die Ähnlichkeit zwischen den direkt benachbarten Bildkacheln durch eine solche Auswahl möglichst gering zu halten. Die Auswahl eines der 5 Testgebiete zur Untersuchung der optimalen Parameter soll eine Annäherung an reale Bedingungen im Kontext der Evaluierung des entwickelten Ansatzes zur DA darstellen, denn im Falle einer realen Anwendung stehen die gelabelten Daten, die zur Parameteroptimierung verwendet werden können, für eine relativ begrenzte Datenmenge in der Quelldomäne zur Verfügung, deren Verteilung sich von der Verteilung der Daten in der Zieldomäne unterscheidet. Die Bilddaten aus dem *Potsdam* Datensatz weisen eine Verteilung im Merkmalsraum auf, die sich von den Verteilungen der Daten aus den anderen Datensätzen unter-

Tabelle 6.2: Übersicht über den Datensatz $\mathfrak{D}_{\mathfrak{U}_1}^{Pot}$ zur Untersuchung der Parameter des Klassifikators und der DA. Der Datensatz beinhaltet 19 von 38 Kacheln des Testgebiets Potsdam, die hier mittels der numerischen Kodierung aus Abbildung 5.2b aufgelistet sind. Die komplette Testreihe für ein Experiment, in dem eine Parametereinstellung untersucht wird, besteht je nach Bewertungskriterium aus 19 (OA_{SS}) oder 361 (OA_{ST} , OA_{DA}) einzelnen Tests.

Datensatz	#Kacheln	#Tests	Testgebiet	Kachel-Nrn.
$\mathfrak{D}_{\mathfrak{U}_1}^{Pot}$	19	19/361	Potsdam	02_11, 02_13, 03_10, 03_12, 03_14, 04_11, 04_13, 04_15, 05_10, 05_12, 05_14, 06_07, 06_09, 06_11, 06_13, 06_15, 07_08, 07_10, 07_12

scheidet. Nichtsdestotrotz weist das Testgebiet Potsdam mit unterschiedlich großen Gebäuden und unterschiedlich ausgeprägter Vegetation eine relativ hohe Variabilität der Erscheinungsformen verschiedener Klassen auf und ist damit repräsentativ genug, um für die Optimierung der Parameter verwendet werden zu können.

Bei jedem Test in diesem Abschnitt wird eine Kachel aus dem verwendeten Datensatz $\mathfrak{D}_{\mathfrak{U}_1}^{Pot}$ als Quelldomäne und eine Kachel als Zieldomäne gewählt. Alle möglichen Kombinationen von Kacheln bilden eine Testreihe, wobei auch die Verwendung einer und derselben Kachel für Quell- und Zieldomäne möglich ist.

Quelle und Ziel. Bei der Analyse der Parameter des initialen Klassifikators wird hier unter der Quelle S die Kachel gemeint, an deren Daten der initiale Klassifikator trainiert wird. Unter dem Ziel T wird hingegen die Kachel verstanden, die zum Testen des initial angelegten Klassifikators verwendet wird.

Experimentenreihe. Zur Ermittlung einer optimalen Einstellung für den jeweiligen Parameter mit dem *Greedy Search* Ansatz werden mehrere Einstellungsmöglichkeiten getestet. Dabei wird pro Experiment eine Parametereinstellung geprüft. Zur Einstellung der Parameter RW und σ_0 werden 6 bzw. 10 Parameterwerte getestet, es finden also 6 bzw. 10 Experimente statt. In Rahmen eines Experiments wird eine Reihe von einzelnen Tests durchgeführt.

Bewertungskriterien. Die Auswertung einer Parametereinstellung erfolgt auf Basis der Gesamtgenauigkeit OA für die Varianten V_{SS} und V_{ST} über eine Testreihe. Eine solche Testreihe besteht somit aus 19 Tests bei der Auswertung in der Variante V_{SS} bzw. aus 361 Tests bei der Auswertung in der Variante V_{ST} (siehe Tabelle 6.2). Die Variante V_{DA} wird zur Auswertung der Tests in diesem Abschnitt zunächst nicht einbezogen, da die untersuchten Parameter keinen direkten Einfluss auf die Kostenfunktion der DA haben. Ein weiteres Kriterium bei der Auswahl einer lokal optimalen Parametereinstellung ist die Rechenzeit.

Ermittlung der Genauigkeiten. Der Parameter für die Rasterweite RW steuert die Gesamtmenge der Trainingsbeispiele in dem Trainingsdatensatz der Quelldomäne. Stichproben der Merkmalsvektoren mit zugehörigen Klassenlabels, die mit Hilfe von *Grid Sampling* aus den Daten einer Quelldomäne extrahiert wurden, bilden dabei ein Trainingsdatensatz. Alle restlichen Stichproben und Referenzdaten der Quelldomäne, die nicht für das Training verwendet wurden, werden zur Ermittlung der Gesamtgenauigkeit OA_{SS} eingesetzt. Die Ermittlung der Gesamtgenauigkeit OA_{ST} erfolgt auf der Gesamtmenge der Stichproben mit zugehörigen Referenzlabels der Daten der Zieldomäne.

6.1.1.3 Ergebnisse

Parameter RW . Die Rasterweite RW beeinflusst in erster Linie die Gesamtmenge der Trainingsbeispiele. Es soll hier eine möglichst kleine Menge der Trainingsbeispiele ausgewählt werden, die einen Kompromiss zwischen der Genauigkeit der Klassifikation und der Rechenzeit darstellt. Zur Analyse des Einflusses von RW auf die Qualität des initialen Klassifikators wurden 6 Experimente durchgeführt, in denen 6 unterschiedliche Einstellungsmöglichkeiten von $RW = 15$ bis $RW = 40$ untersucht wurden. Die Ergebnisse sind in Abbildung 6.1 vorgestellt. Für $RW = 15$ beträgt die Anzahl der gezogenen Trainingsbeispiele 62500 (ca. 0.5% der Gesamtmenge der Pixel in einer Domäne), für $RW = 25$ sind es 22500 Trainingsbeispiele (ca. 0.2% der Gesamtmenge) und für $RW = 40$ nur 8836 Trainingsbeispiele (weniger als 0.1% der Gesamtmenge). Die Werte OA_{SS} für die Rasterweite RW zeigen einen systematischen Abfall der Genauigkeit mit steigender Rasterweite: der Median der Genauigkeit über die Testreihe fällt um 1% von 80.5% bis 79.5% für RW von 15 bis 40. Auch die minimalen und maximalen Werte von OA_{SS} zeichnen einen Abfall der Genauigkeit mit steigender Rasterweite bei steigender Standardabweichung der Ergebnisse ab. Die Medianwerte von OA_{ST} fallen von 75.6% bis 75.0% mit steigender Rasterweite. Die minimalen Werte von OA_{ST} steigen leicht von 43.1% bis 45.0% an, wobei die maximalen Werte einen leichten Abfall von 87.8% bei $RW = 15$ bis 87.3% bei $RW = 40$ zeigen. Insgesamt zeigt die Rasterweite RW in dem untersuchten Bereich jedoch keinen signifikanten Einfluss auf OA_{ST} und damit auf den initialen Klassifikator (bei der Klassifikation der Daten aus der Zieldomäne), der die Ausgangslage für die DA darstellt. Zugleich steigt mit der Anzahl der Trainingsbeispiele (umgekehrt proportional zu RW) die Rechenzeit pro Test (die Laufzeitkomplexität wächst quadratisch mit der Rasterweite RW). Von diesem Hintergrund und unter Berücksichtigung der Rechenzeit wird die Gesamtanzahl der Trainingsdaten von ca. 22000 (entspricht hier der Rasterweite von $RW = 25$) ausgewählt.

Parameter σ_0 . Als Nächstes wird der Parameter σ_0 zur Steuerung der Regularisierung während des initialen Trainings des Klassifikators untersucht (siehe Kapitel 4.2.2). Kleine Werte von σ_0 führen zu einer stärkeren Regularisierung und umgekehrt wird die Überanpassung des Klassifikators bei größeren Werten von σ_0 weniger bestraft. Es fanden insgesamt 10 Experimente statt, in denen 10 unterschiedliche Werte von $\sigma_0 = 0.2$ bis $\sigma_0 = 50.0$ getestet wurden. Die Rechenzeit wird durch eine Änderung des Parameters σ_0 nicht beeinflusst. Die Ergebnisse der OA sind in Abbildung 6.2 vorgestellt. Die Medianwerte der OA_{SS} steigen von 76.6% bis 81.1% für $\sigma_0 = 0.2$ bis $\sigma_0 = 50.0$ an und weisen eine Sättigung für größere Werte von σ_0 auf. Der optimale Wert des Parameters wird auf Basis der Auswertung auf der Zieldomäne (Variante V_{ST}) ermittelt. Die Charakteristika der OA_{ST} Werte verbessern sich zuerst bis zu $\sigma_0 = 1.5$, dann werden sie wieder geringfügig schlechter. Die Medianwerte steigen noch leicht von $OA_{ST} = 75.3%$ bei $\sigma_0 = 1.5$ bis $OA_{ST} = 75.5%$ bei $\sigma_0 = 2.9$ und stagnieren dann auf diesem Wert für größere σ_0 . Jedoch verschlechtern sich der untere Whisker, die minimalen Werte sowie die Standardabweichung deutlich für $\sigma_0 > 1.5$ (siehe Abbildung 6.2b). Der Wert des Parameters für die Regularisierung des initialen Klassifikators wird hier auf $\sigma_0 = 1.5$ gesetzt. Dieser scheint eine gute Alternative zwischen den relativ hohen Genauigkeitswerten und angemessener Regularisierung zu sein, um eine Überanpassung des Klassifikators an die Daten der Quelldomäne zu vermeiden.

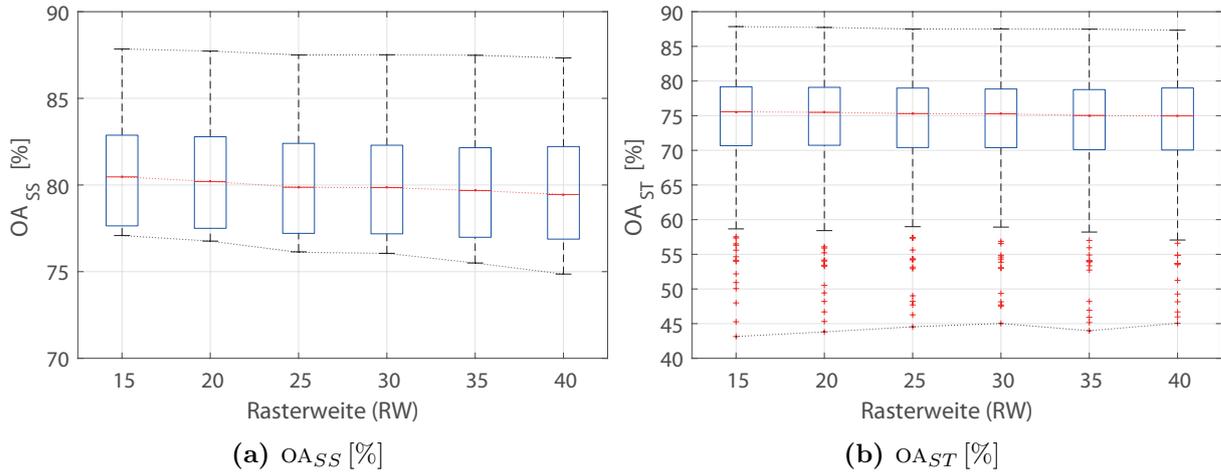


Abbildung 6.1: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{SS} (a) und OA_{ST} (b) bei der Untersuchung der Rasterweite RW für die Erzeugung der Trainingsdaten. Exakte Werte sind in Tabelle 6.3 zusammengefasst.

Tabelle 6.3: Genauigkeitswerte für OA_{SS} (a) und OA_{ST} (b) aus Abbildung 6.1 bei der Untersuchung der Rasterweite RW ($\#TB$: Anzahl der Trainingsbeispiele aus der Quelldomäne; Med.: Median; Std: Standardabweichung).

RW	15	20	25	30	35	40	RW	15	20	25	30	35	40
$\#TB$	62500	35344	22500	15625	11664	8836	$\#TB$	62500	35344	22500	15625	11664	8836
Med.	80.5	80.2	79.9	79.8	79.7	79.5	Med.	75.6	75.5	75.3	75.3	75.0	75.0
Min	77.1	76.8	76.2	76.1	75.5	74.9	Min	43.1	43.8	44.5	45.0	44.0	45.0
Max	87.8	87.7	87.5	87.5	87.5	87.3	Max	87.8	87.7	87.5	87.5	87.5	87.3
Std	3.3	3.3	3.4	3.4	3.5	3.5	Std	7.6	7.6	7.6	7.6	7.7	7.7

6.1.2 Parameter der Domänenadaption

6.1.2.1 Zielsetzung

Die zweite Gruppe umfasst 7 Parameter, die vom Benutzer manuell gesetzt werden müssen. Zu diesen Parametern zählen der Parameter σ_{DA} zur Steuerung der Regularisierung während der DA, der Parameter ρ für die Anzahl der in einer DA Iteration auszutauschenden Trainingsbeispiele ($\rho = \rho_S = \rho_T$), die Anzahl k der Nachbarn bei der k -NN Analyse, der Parameter γ der Gewichtsfunktion $g(p_n, \gamma)$ aus Gleichung 4.15 sowie drei Parameter von der Funktion zur Anpassung des Gewichts i_{max} , $g_{S,max}$ und $g_{T,max}$ aus Gleichung 4.16. Eine Zusammenfassung der Parameter ist in Tabelle 4.2 zu finden. Diese Parameter haben einen direkten Einfluss auf die Qualität der DA, welcher hier untersucht werden soll. Darüber hinaus soll die Sensitivität des Verfahrens gegenüber den Parametereinstellungen analysiert werden. Im Rahmen der Untersuchung sollen optimale Parametereinstellungen bestimmt werden. Dabei ist neben der Qualität der DA die Rechenzeit ein wichtiges Kriterium bei der Auswahl einer optimalen Einstellung. Das Ziel der Experimente ist es also, die optimalen Einstellungen für die oben genannte Parameter unter Berücksichtigung der Genauigkeit der DA und der Rechenzeit zu ermitteln.

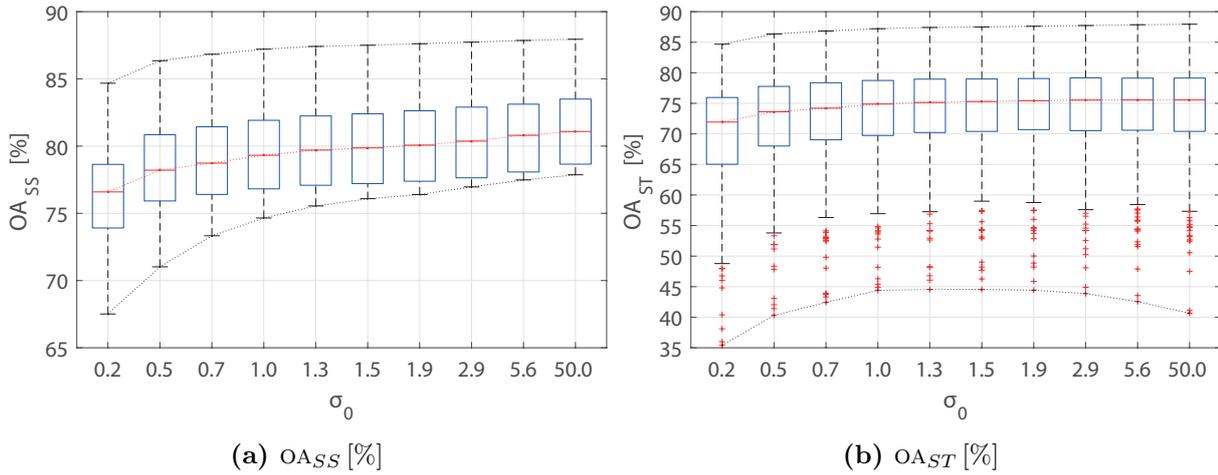


Abbildung 6.2: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{SS} (a) und OA_{ST} (b) bei der Untersuchung des Parameters σ_0 zur Steuerung der Regularisierung des Klassifikators beim initialen Training. Exakte Werte sind in Tabelle 6.4 zusammengefasst.

Tabelle 6.4: Genauigkeitswerte für OA_{SS} (a) und OA_{ST} (b) aus Abbildung 6.2 bei der Untersuchung des Parameters σ_0 (Med.: Median; Std: Standardabweichung).

σ_0	0.2	0.5	0.7	1.0	1.3	1.5	1.9	2.9	5.6	50.0	σ_0	0.2	0.5	0.7	1.0	1.3	1.5	1.9	2.9	5.6	50.0		
Med.	76.6	78.2	78.7	79.3	79.7	79.9	80.1	80.4	80.8	81.1	Med.	71.9	73.6	74.2	74.9	75.1	75.3	75.4	75.5	75.5	75.5	75.5	
Min	67.5	71.0	73.3	74.7	75.5	76.2	76.4	77.0	77.5	77.9	Min	35.4	40.3	42.4	44.4	44.6	44.5	44.4	43.9	42.6	40.7	40.7	
Max	84.7	86.4	86.8	87.2	87.4	87.5	87.6	87.7	87.9	87.9	Max	84.7	86.4	86.8	87.2	87.4	87.5	87.6	87.7	87.9	87.9	87.9	87.9
Std	4.2	4.0	3.8	3.6	3.5	3.4	3.4	3.3	3.2	3.1	Std	9.0	8.3	8.1	7.8	7.7	7.6	7.6	7.5	7.6	7.6	7.8	7.8

(a) OA_{SS} [%]

(b) OA_{ST} [%]

6.1.2.2 Durchführung der Experimente

Vorgehensweise zur Bestimmung der Parametereinstellungen. Die im vorherigen Abschnitt ermittelten Werte für RW und σ_0 werden hier fürs Training des initialen Klassifikators eingesetzt. Die Bestimmung der optimalen Werte der Parameter der DA erfolgt hier analog zu der vorherigen Untersuchung auf Basis einer empirischen Untersuchung mit dem Greedy Ansatz (siehe Kapitel 6.1.1.2).

Datensatz. Die experimentelle Untersuchung erfolgt auf dem *Potsdam* Datensatz $\mathcal{D}_{M_1}^{Pot}$, der mit dem Datensatz aus der vorherigen Untersuchung identisch ist (siehe Tabelle 6.2).

Quelle und Ziel. Unter einer Quelle S ist hier die Kachel gemeint, an deren Daten der initiale Klassifikator trainiert wird. Als ein Ziel T wird die Kachel bezeichnet, die zum Testen der DA verwendet wird. Die entsprechenden Daten, die aus den Bildkacheln extrahiert werden, werden als Daten der Quell- bzw. Zieldomäne bezeichnet.

Experimentenreihe. Zur Ermittlung einer Parametereinstellungen werden mehrere Experimente durchgeführt. Pro Experiment kann eine Parametereinstellung getestet werden. Dabei wird im Rahmen eines Experiments eine Reihe von einzelnen Tests durchgeführt. Bei jedem Test der Testreihe wird eine Kachel aus dem verwendeten Datensatz $\mathcal{D}_{M_1}^{Pot}$ als Quelldomäne und eine Kachel als Zieldomäne gewählt. Alle möglichen Kombinationen von Kacheln bilden eine Testreihe, wobei die Verwendung einer und derselben Kachel für Quell- und Zieldomäne möglich ist. Damit besteht die Testreihe von einem Experiment aus 361 einzelnen Tests (siehe Tabelle 6.2).

Bewertungskriterien. Die Auswertung einer Parametereinstellung erfolgt auf Basis der Gesamtgenauigkeit OA für die Variante V_{DA} , also nach Anwendung des entwickelten Ansatzes zur DA. Ein weiteres Kriterium bei der Auswahl einer lokal optimalen Parametereinstellung ist die Rechenzeit.

Ermittlung der Genauigkeit. Der Parameter RW steuert die Gesamtmenge der Trainingsbeispiele in dem Trainingsdatensatz der Quelldomäne, an denen der initiale Klassifikator angeleitet wird. Mit Hilfe der Rasterweite wird hier gleiche Anzahl der Merkmalsvektoren aus der Zieldomäne (ohne Labels) extrahiert, die zur Anpassung des Klassifikators mittels DA verwendet werden. Die Ermittlung der Gesamtgenauigkeit der Klassifikation nach der DA erfolgt anschließend auf der Gesamtmenge der Stichproben und den zugehörigen Referenzlabels der Daten aus der Zieldomäne.

6.1.2.3 Ergebnisse

Parameter σ_{DA} . Zunächst wird der Parameter zur Steuerung der Regularisierung σ_{DA} beim Anpassen des Klassifikators während der DA untersucht. In einer Reihe von Experimenten wurden 13 unterschiedliche Werte zwischen $\sigma_{DA} = 0.2$ und $\sigma_{DA} = 50.0$ getestet. Die Ergebnisse sind in Abbildung 6.3 zu sehen. Die Medianwerte der OA_{DA} steigen von 72.2% bei $\sigma_{DA} = 0.2$ bis 74.8% bei $\sigma_{DA} = 10.0$ und fallen langsam wieder bis zu 73.2% bei $\sigma_{DA} = 50.0$. Die Rechenzeit wird durch eine Änderung des Parameters σ_{DA} nicht beeinflusst. Im Vergleich zu σ_0 liefert DA bessere Ergebnisse für relative große Werte des Regularisierungsparameters σ_{DA} . Mit größerem Wert von σ_{DA} werden die Abweichungen von den aktuellen Parameterwerten weniger stark bestraft. Dadurch wird die Anpassung an die neue Verteilung erleichtert. Als optimaler Wert für den Parameter wird $\sigma_{DA} = 20.0$ ausgewählt. Bei diesem Wert liefert die DA lediglich einen geringfügig schlechteren Medianwert der Gesamtgenauigkeit über die Testreihe als bei $\sigma_{DA} = 10.0$ (74.8% gegenüber 74.6%). Dafür erreicht die DA bei $\sigma_{DA} = 20.0$ den besten oberen und unteren Whisker (zwischen 53% und 88%) unter den untersuchten Fällen und einen relativ kleinen Wert der Standardabweichung von 8.5% (siehe Abbildung 6.3).

Parameter ρ . Als Nächstes wird der Parameter ρ untersucht. Dieser definiert, gemäß der Beschreibung aus Kapitel 4.3.1, die Anzahl der auszutauschenden Trainingsbeispiele pro Klasse in einer DA Iteration, wobei $\rho = \rho_S = \rho_T$ gilt. Es wurden insgesamt 9 Einstellungen zwischen $\rho = 30$ und $\rho = 400$ getestet. Die Ergebnisse sind in Abbildung 6.4 vorgestellt. Die Medianwerte der OA_{DA} variieren kaum; sie steigen leicht von 74.6% bei $\rho = 30$ bis 75.7% bei $\rho = 400$. Die Streuung der Ergebnisse verbessert sich mit zunehmenden Werten von ρ von 8.5% auf 7.8%. Die relativ ähnlichen Charakteristika ab $\rho = 200$ könnten auf eine Sättigung hindeuten: Medianwerte sind fast gleich, die unteren und oberen Whisker pendeln sich auf das Niveau von jeweils etwa 59.0% und 87.6% ein und die Standardabweichungen liegen bei 7.8%. Die Parametereinstellung $\rho = 250$ weist den besten Median- und Minimumwert sowie einen sehr guten Maximumwert der OA_{DA} und spart gegenüber einer kleineren Einstellung zusätzlich Rechenzeit. Unter diesen Bedingungen wird $\rho = 250$ als optimaler Parameter ausgewählt. Mit $\rho = 250$ konvergiert die DA nach ca. 30 bis 50 Iterationen gegenüber etwa 200 Iterationen bei $\rho = 30$.

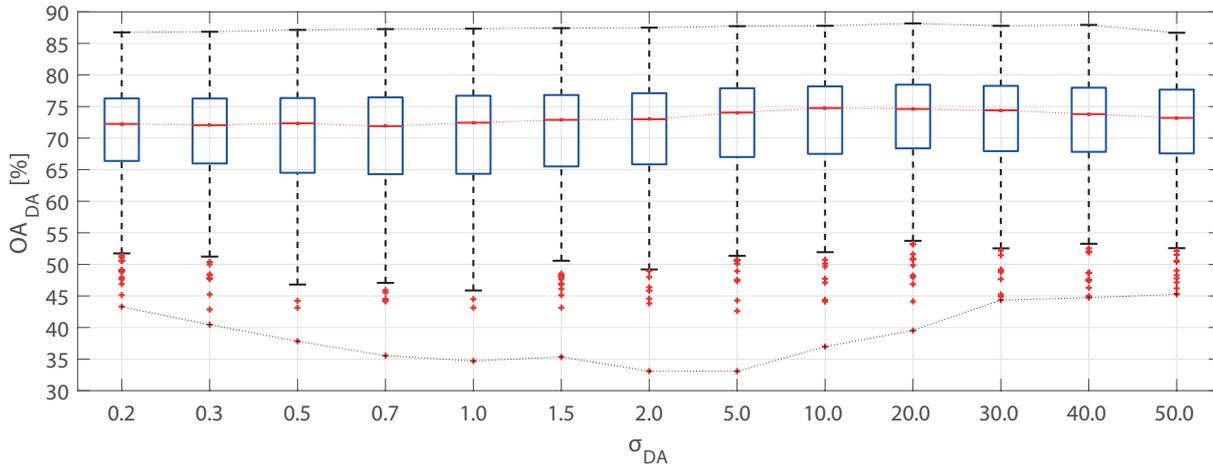


Abbildung 6.3: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{DA} [%] bei der Untersuchung des Parameters σ_{DA} zur Steuerung der Regularisierung des Klassifikators während der DA. Exakte Werte sind in Tabelle 6.5 zusammengefasst.

Tabelle 6.5: Genauigkeitswerte für OA_{DA} [%] aus Abbildung 6.3 bei der Untersuchung des Parameters σ_{DA} (Med.: Median; Std: Standardabweichung).

σ_{DA}	0.2	0.3	0.5	0.7	1.0	1.5	2.0	5.0	10.0	20.0	30.0	40.0	50.0
Med.	72.2	72.1	72.3	71.9	72.4	72.9	73.0	74.0	74.8	74.6	74.4	73.8	73.2
Min	43.3	40.5	37.8	35.5	34.7	35.3	33.1	33.1	37.0	39.5	44.3	44.7	45.3
Max	86.8	86.8	87.1	87.3	87.3	87.4	87.5	87.7	87.8	88.2	87.8	87.9	86.7
Std	8.1	8.4	8.7	8.8	8.9	9.0	9.0	8.9	8.7	8.5	8.5	8.5	8.6

Parameter k . Im nächsten Schritt wird die Anzahl der Nachbarn k bei der k -NN Analyse für das Kriterium zur Auswahl der Trainingsbeispiele aus der Zieldomäne (Kapitel 4.3.2) analysiert. Es wurden insgesamt 11 unterschiedlich große Nachbarschaften zwischen $k = 5$ und $k = 150$ untersucht. Die Ergebnisse sind in Abbildung 6.5 präsentiert. Die resultierenden Gesamtgenauigkeiten weisen mit wenigen Ausnahmen einen langsamen Abfall mit steigender Größe der Nachbarschaft auf. Die Medianwerte der OA_{DA} fallen beispielsweise von 75.9% bei $k = 5$ bis 74.9% bei $k = 150$ (siehe Tabelle 6.7). Eine mögliche Erklärung für dieses Verhalten könnte sein, dass die Trainingsbeispiele in der Nähe einer Entscheidungsgrenze bei einer großen zu untersuchenden Nachbarschaft aufgrund der Überprüfung der Klassenlabels auf Konsistenz erst viel später in den Trainingsdatensatz übernommen werden. Dies hat vor allem für Klassen mit wenigen Trainingsbeispielen negative Auswirkungen, die im Merkmalsraum eine starke Überlappung mit Verteilungen anderer Klassen aufweisen, wie z.B. die stark unterrepräsentierte und heterogene Klasse *Sonstiges* (siehe klassenspezifische Qualitätskriterien in Tabelle 6.8). Trotz des Abfalls der Genauigkeiten für größere Werte von k weisen die Genauigkeitscharakteristika der Experimente mit $k = 5$ und $k = 10$ kaum Unterschiede auf (vgl. Tabelle 6.7). Zugleich liefern die größeren Werte von k eine größere Sicherheit bei der Entscheidung für ein Semi-Label mit Hilfe der k -NN Analyse. Weiterhin wird durch die Wahl eines kleineren Wertes von k die Rechenzeit aufgrund der Suche nach den NN mit dem binären KD -Baum eingespart. Aus den oben genannten Gründen wird die Anzahl der Nachbarn k von dem initialen Wert $k = 19$ auf den Wert $k = 10$ reduziert. Die ausgewählte Parametereinstellung $k = 10$ stellt ein Kompromiss zwischen Genauigkeit OA_{DA} , Sicherheit bei der Entscheidung für ein Semi-Label und der Rechenzeit dar.

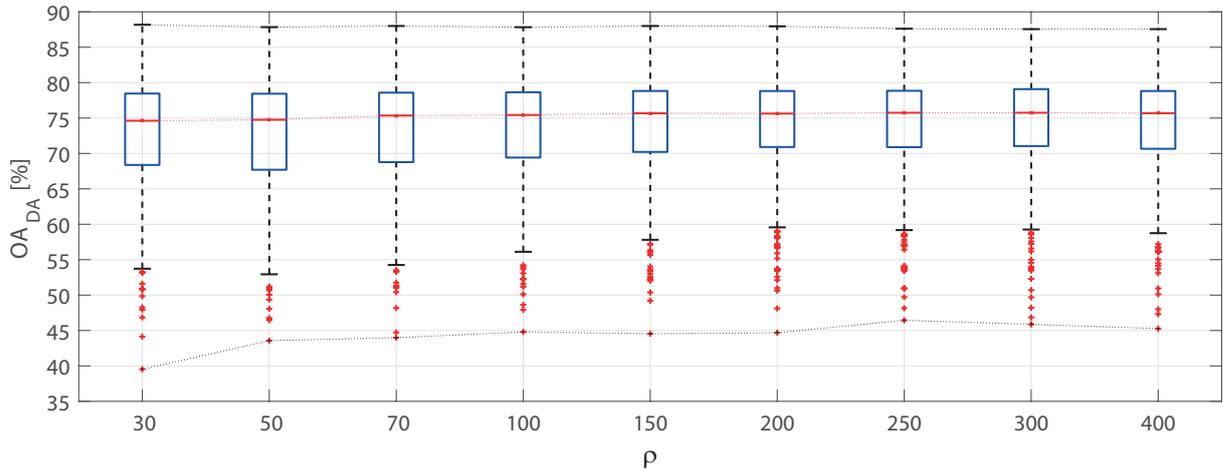


Abbildung 6.4: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{DA} [%] bei der Untersuchung des Parameters ρ , mit dessen Hilfe die Anzahl der auszutauschenden Trainingsbeispiele pro Klasse in einer DA Iteration definiert wird. Exakte Werte sind in Tabelle 6.6 zusammengefasst.

Tabelle 6.6: Genauigkeitswerte für OA_{DA} [%] aus Abbildung 6.4 bei der Untersuchung des Parameters ρ (Med.: Median; Std: Standardabweichung).

ρ	30	50	70	100	150	200	250	300	400
Med.	74.6	74.8	75.4	75.4	75.7	75.6	75.7	75.7	75.7
Min	39.5	43.6	44.0	44.8	44.5	44.7	46.4	45.9	45.3
Max	88.2	87.8	88.0	87.8	88.0	88.0	87.6	87.6	87.6
Std	8.5	8.4	8.2	8.0	7.9	7.8	7.8	7.8	7.8

Parameter γ . Die weiteren Untersuchungen beschäftigen sich mit den Parametern, mit deren Hilfe die Gewichte von Trainingsbeispielen definiert bzw. iterativ angepasst werden: γ , i_{max} , $g_{S,max}$, $g_{T,max}$. Die Rechenzeit wird durch eine Änderung dieser Parameter kaum beeinflusst. Aus diesem Grund wird sie im Weiteren kein Kriterium zur Auswahl einer Parametereinstellung sein. Zuerst wird der Parameter γ zur Definition der Gewichte mit Hilfe der Funktion $g(p_n, \gamma)$ für jedes Trainingsbeispiel gemäß der Gleichung 4.15 untersucht. Es wurden insgesamt 9 mögliche Einstellungen für den Wert des Parameters γ zwischen $\gamma = 0.1$ und $\gamma = 0.9$ untersucht. Die Ergebnisse sind in Abbildung 6.6 präsentiert. Die Medianwerte der OA_{DA} ändern sich nur leicht, sie steigen um 0.7% von 75.3% bei $\gamma = 0.1$ bis 75.9% bei $\gamma = 0.5$ und fallen dann wieder auf 75.8% bei $\gamma = 0.9$. Ebenso steigt der Wert der unteren Whisker in den einzelnen Testreihen von etwa 54% bei $\gamma = 0.1$ bis auf ca. 59% bei $\gamma = 0.6$ an und dann verharrt er auf einem etwas kleineren Niveau von ca. 58% für die restlichen Werte von γ . Die maximalen Werte ändern sich für alle untersuchten Einstellungen kaum. Sie pendeln zwischen 87.5% und 87.9%, wobei der erreichte maximaler Wert von OA_{DA} für $\gamma = 0.5$ bei 87.9% liegt. Die Werte der Standardabweichung verbessern sich kontinuierlich von 7.9% bis 7.6% mit steigenden Werten von γ . Es wird hier deswegen die Einstellung $\gamma = 0.5$ mit den besten erreichten Genauigkeitswerten ausgewählt.

Parameter i_{max} . Als Nächstes wird Parameter i_{max} für die Anzahl der Iterationen in der Funktion zur Anpassung des Gewichtes gemäß Gleichung 4.16 näher betrachtet. Es wurden insgesamt 6 unterschiedliche Experimente durchgeführt und die Ergebnisse für i_{max} zwischen $i_{max} = 10$ und $i_{max} = 100$ analysiert. Die Ergebnisse sind in Abbildung 6.7 zu sehen. Die statistischen Parameterwerte für alle Einstellungen weisen mit Ausnahme von $i_{max} = 100$ sehr ähnliche Werte auf. Die Werte OA_{DA} liegen für die Einstellungen $i_{max} = 10$ bis $i_{max} = 50$

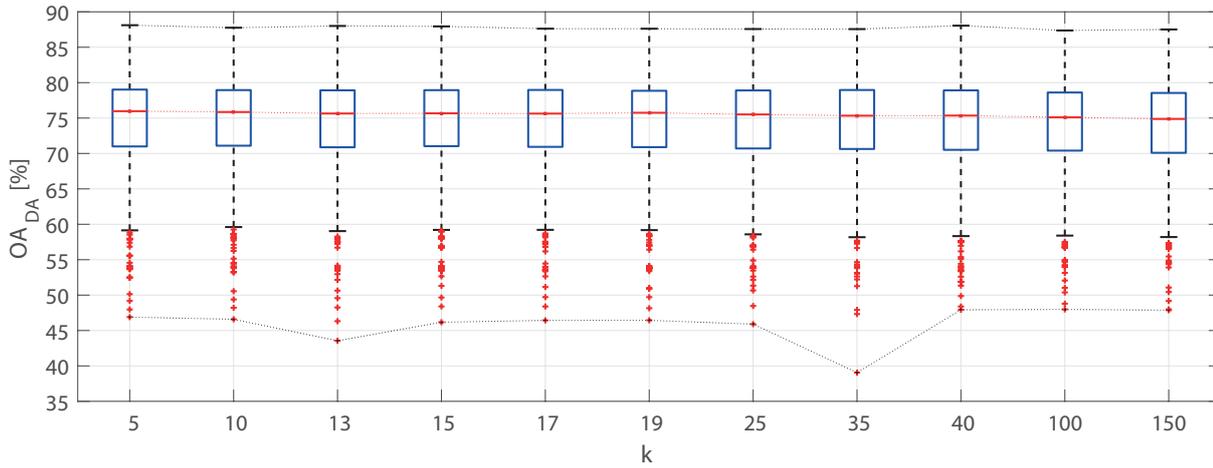


Abbildung 6.5: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{DA} [%] bei der Untersuchung des Parameters k für die k -NN Analyse bei der Auswahl der Trainingsbeispiele aus der Zieldomäne. Exakte Werte sind in Tabelle 6.7 zusammengefasst.

Tabelle 6.7: Genauigkeitswerte für OA_{DA} [%] aus Abbildung 6.5 bei der Untersuchung des Parameters k (Med.: Median; Std: Standardabweichung).

k	5	10	13	15	17	19	25	35	40	100	150
Med.	75.9	75.8	75.6	75.7	75.6	75.7	75.5	75.3	75.3	75.1	74.9
Min	46.9	46.6	43.6	46.2	46.4	46.4	45.9	39.1	47.9	48.0	47.9
Max	88.1	87.8	88.0	87.9	87.6	87.6	87.6	87.6	88.0	87.4	87.5
Std	7.7	7.7	7.9	7.7	7.7	7.8	7.8	7.9	7.9	7.7	7.7

Tabelle 6.8: Mittlere klassenspezifische Genauigkeitsmaße Vollständigkeit (Comp), Korrektheit (Corr) und F1-Maß (F1) für die Variante V_{DA} mit drei unterschiedlichen Einstellungen des Parameters k (Vers.: *Versiegelte Fläche*, Geb.: *Gebäude*, N.Veg.: *Niedrige Vegetation*, Baum: *Baum*, Sons.: *Sonstiges*; MW: Mittelwert).

Variante V_{DA}			Vers.	Geb.	N.Veg.	Baum	Sons.
$k = 10$	Comp	[%]	83.3	89.3	70.4	56.2	8.5
	Corr	[%]	78.7	88.9	65.0	56.5	21.9
	F1	[%]	79.4	88.8	66.0	55.2	9.7
$k = 35$	Comp	[%]	83.0	89.1	70.2	55.8	7.8
	Corr	[%]	78.6	89.0	64.5	55.6	20.4
	F1	[%]	79.3	88.7	65.6	54.5	8.8
$k = 150$	Comp	[%]	83.8	87.8	70.8	53.5	6.3
	Corr	[%]	78.0	89.1	63.0	55.4	19.0
	F1	[%]	79.2	88.2	65.1	53.2	7.3

im Bereich von 44.8% bis 88.1%, während der Minimum bei $i_{max} = 100$ auf 36.3% fällt. Eine mögliche Begründung für größere Ausreißer nach unten bei $i_{max} = 100$ liegt in der Strategie zur Gewichtung der Trainingsbeispiele. Die Anpassung des Gewichts während der DA gemäß der Gleichung 4.16 erfolgt hier aufgrund der quadratischen Abhängigkeit wesentlich langsamer als bei einem kleineren Wert von i_{max} . Außerdem wird das maximale Gewicht $g_{S,max}$ bzw. $g_{T,max}$ bei $i_{max} = 100$ bedingt durch die ausgewählte Einstellung für den Parameter ρ für keines der Trainingsbeispiele erreicht, weil die DA damit weniger als 50 Iterationen zur Konvergenz in allen Tests braucht. Trotz dem Verhalten bei $i_{max} = 100$ zeigen die Medianwerte für alle Experimente nur geringfügige Unterschiede von 75.8% bis 76.0%, wobei der maximale Wert von 76.0% bei der Parametereinstellung $i_{max} = 20, 50$ und 100 Iterationen auftritt. Als optimaler Parameter wird die Anzahl der Iterationen von $i_{max} = 20$ ausgewählt, die außer dem besten Medianwert von 76.0% den besten minimalen Wert von 45.8% aufweist.

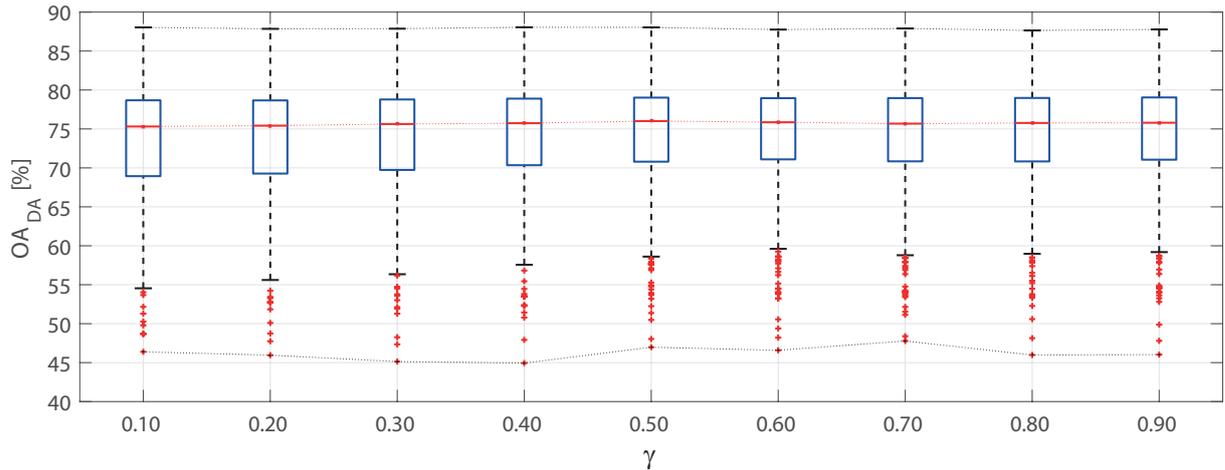


Abbildung 6.6: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{DA} [%] bei der Untersuchung des Parameters γ zur Definition der Gewichte mithilfe der Gewichtsfunktion $g(p_n, \gamma)$. Exakte Werte sind in Tabelle 6.9 zusammengefasst.

Tabelle 6.9: Genauigkeitswerte für OA_{DA} [%] aus Abbildung 6.6 bei der Untersuchung des Parameters γ (Med.: Median; Std: Standardabweichung).

γ	0.10	0.20	0.30	0.40	0.50	0.60	0.70	0.80	0.90
Med.	75.3	75.4	75.6	75.7	75.9	75.8	75.7	75.8	75.8
Min	46.4	46.0	45.1	44.9	46.8	46.6	47.5	46.0	46.0
Max	87.9	87.7	87.8	87.9	87.9	87.8	87.8	87.5	87.7
Std	7.9	7.8	7.8	7.7	7.7	7.7	7.7	7.6	7.6

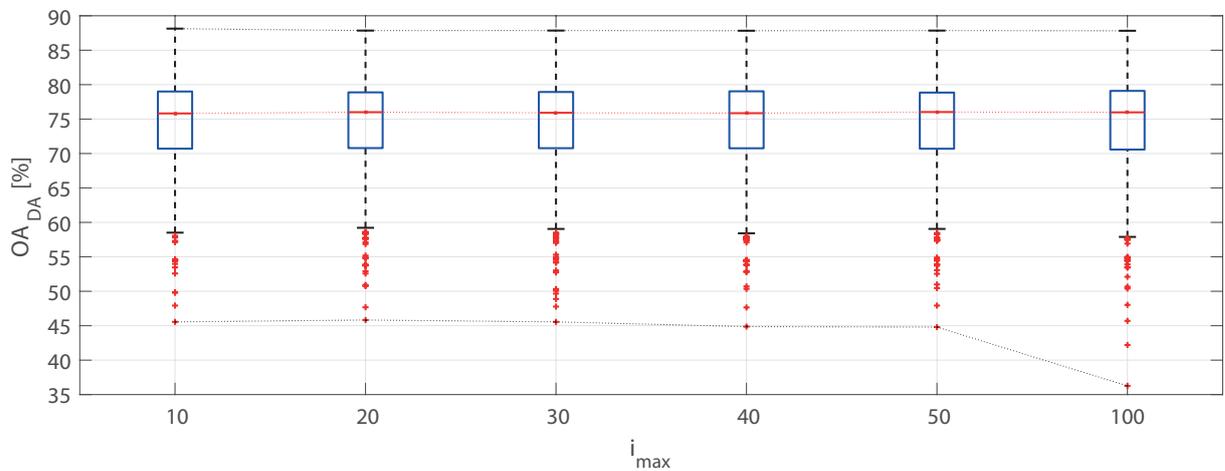


Abbildung 6.7: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{DA} [%] bei der Untersuchung des Parameters i_{max} zur iterativen Anpassung des Gewichtes eines Trainingsbeispiels während der DA. Exakte Werte sind in Tabelle 6.10 zusammengefasst.

Tabelle 6.10: Genauigkeitswerte für OA_{DA} [%] aus Abbildung 6.7 bei der Untersuchung des Parameters i_{max} (Med.: Median; Std: Standardabweichung).

i_{max}	10	20	30	40	50	100
Med.	75.8	76.0	75.9	75.9	76.0	76.0
Min	45.6	45.8	45.6	44.9	44.8	36.3
Max	88.1	87.8	87.9	87.8	87.8	87.8
Std	7.7	7.7	7.9	7.7	7.7	8.2

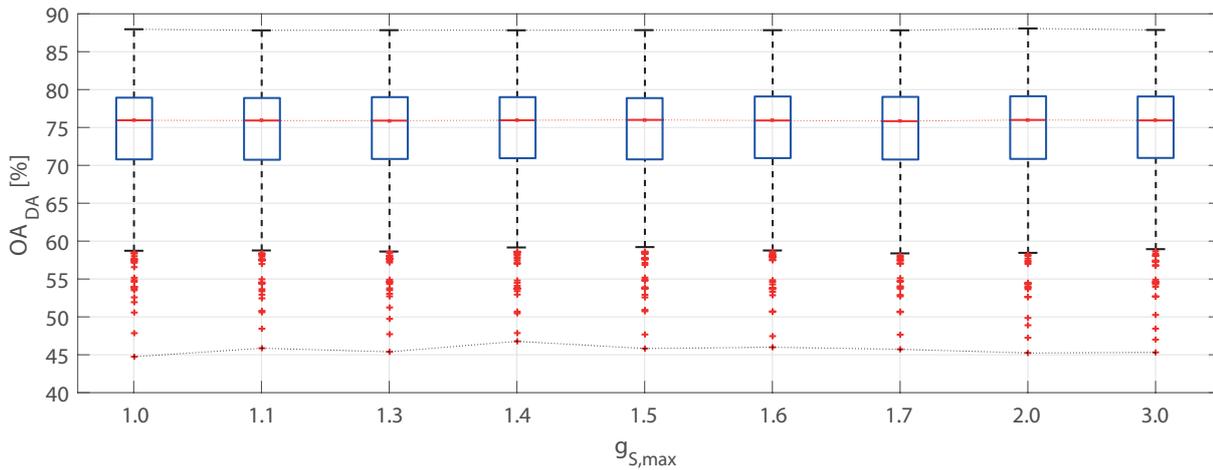


Abbildung 6.8: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{DA} [%] bei der Untersuchung des maximalen Wertes $g_{S,max}$ eines Gewichtes aus der Quelldomäne während seiner iterativen Anpassung im DA Prozess. Exakte Werte sind in Tabelle 6.11 zusammengefasst.

Tabelle 6.11: Genauigkeitswerte für OA_{DA} [%] aus Abbildung 6.8 bei der Untersuchung des Parameters $g_{S,max}$ (Med.: Median; Std: Standardabweichung).

$g_{S,max}$	1.0	1.1	1.3	1.4	1.5	1.6	1.7	2.0	3.0
Med.	76.0	75.9	75.9	76.0	76.0	75.9	75.8	76.0	75.9
Min	44.7	45.9	45.4	46.8	45.8	46.0	45.7	45.2	45.3
Max	88.0	87.8	87.8	87.8	87.8	87.8	87.8	88.1	87.9
Std	7.7	7.7	7.7	7.7	7.7	7.7	7.7	7.8	7.7

Parameter $g_{S,max}$, $g_{T,max}$. Die beiden letzten Parameter $g_{S,max}$ und $g_{T,max}$ für das maximal mögliche Gewicht eines Trainingsbeispiels der Quell- bzw. Zieldomäne in Rahmen der Anpassung eines Gewichtes gemäß der Gleichung 4.16 weisen kaum einen Einfluss auf das Ergebnis der DA auf. Die Ergebnisse der Untersuchung der beiden Parameter sind in Abbildungen 6.8 und 6.9 präsentiert. Die geringfügigen Unterschiede der Klassifikationsgenauigkeit über die untersuchten Werte weisen auf eine geringe Bedeutung dieser Parameter hin. Hier werden die Parameterwerte $g_{S,max} = 1.4$ und $g_{T,max} = 0.9$ ausgewählt, weil diese Einstellungen etwas bessere Medianwerte sowie gute minimale und maximale Werte aufweisen. Diese Einstellungen werden für die darauf folgende Evaluierung fixiert.

Optimale Einstellung und Sensitivität der Parameter. Die optimalen Einstellungen für alle Parameter nach dem Greedy Search Ansatz sind in der Tabelle 6.13 zusammengefasst. In Bezug auf die Sensitivität gegenüber der Parametereinstellungen für die DA verhält sich das Modell relativ stabil, wie es aus den Abbildungen 6.3 bis 6.9 ersichtlich ist. Es treten in den untersuchten Bereichen der Parameter, mit Ausnahme von einzelnen Ausreißern nach unten, keine unerwarteten Sprünge auf. Die Variabilität der Ergebnisse in der Testreihe (Standardabweichung) wird vor allem durch die Einstellung der Parameter σ_{DA} und ρ reduziert. Bei deren Einstellung verbesserte sich der Wertebereich der Gesamtgenauigkeit OA_{DA} von [35.3%; 87.4%] mit Median 72.9% bereits auf [46.4%; 87.6%] mit Median 75.7%. Zugleich verbesserte sich die Standardabweichung der Ergebnisse innerhalb der Testreihe von 9.0% auf 7.8%. Daraus lässt sich schließen, dass im Falle einer Anpassung der Parameter (z.B. für eine andere Aufgabe) mit dem gleichen Prozedere der Einstellung dieser beiden Parameter die höchste Aufmerksamkeit geschenkt werden sollte.

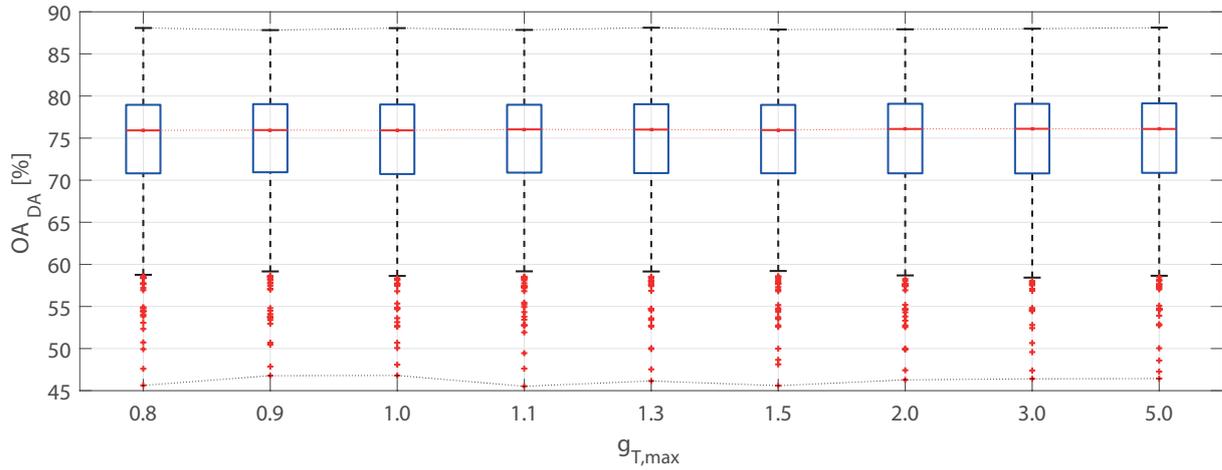


Abbildung 6.9: Box-Plots mit den resultierenden Gesamtgenauigkeiten OA_{DA} [%] bei der Untersuchung des maximalen Wertes $g_{T,max}$ eines Gewichtes aus der Zieldomäne während seiner iterativen Anpassung im DA Prozess. Exakte Werte sind in Tabelle 6.12 zusammengefasst.

Tabelle 6.12: Genauigkeitswerte für OA_{DA} [%] aus Abbildung 6.9 bei der Untersuchung des Parameters $g_{T,max}$ (Med.: Median; Std: Standardabweichung).

$g_{T,max}$	0.8	0.9	1.0	1.1	1.3	1.5	2.0	3.0	5.0
Med.	75.9	76.0	75.9	76.0	76.0	76.0	76.0	76.0	76.0
Min	45.6	46.8	46.8	45.5	46.2	45.6	46.3	46.4	46.4
Max	88.1	87.8	88.1	87.9	88.1	87.9	87.9	87.9	88.0
Std	7.7	7.7	7.7	7.7	7.7	7.7	7.7	7.8	7.8

Tabelle 6.13: Optimierte Einstellungen für alle Parameter nach dem Greedy Search Ansatz.

RW (#Trainingsdaten)	Optimale Parameter							
	σ_0	σ_{DA}	ρ	k	γ	i_{max}	$g_{S,max}$	$g_{T,max}$
25 (ca. 22000)	1.5	20.0	250	10	0.5	20	1.4	0.9

6.1.3 Analyse der Parametereinstellungen

In diesem Abschnitt werden Ergebnisse der DA vor und nach der Optimierung der Parametereinstellungen analysiert. Die Analyse der Ergebnisse vor und nach der Optimierung erfolgt auf dem *Potsdam* Datensatz $\mathcal{D}_{\Omega_1}^{Pot}$ (siehe Tabelle 6.2). Die Testreihe besteht jeweils aus 361 einzelnen Tests. Die Qualität der DA vor Optimierung wird mit den Parameterwerten aus der Tabelle 6.1 und nach der Optimierung mit den Einstellungen aus der Tabelle 6.13 ermittelt. Die Auswertung der Ergebnisse der Gesamtgenauigkeiten über die komplette Testreihe vor und nach der Optimierung ist in der Tabelle 6.14 vorgestellt. Die Genauigkeitswerte für die OA_{SS} und OA_{ST} haben sich nach der Optimierung im Vergleich zu dem Ausgangszustand nur wenig verbessert. Im Unterschied dazu stiegen die Werte von Median und Mittelwert von OA_{DA} um 2.0% bzw. 2.3% auf 76.0% bzw. 74.0% nach der Optimierung. Der Median und Mittelwert von ΔOA_{DA} signalisieren mit den entsprechenden Werten von -0.8% bzw. -2.2% einen negativen Transfer über die ganze Testreihe vor der Optimierung. Der Median von 0.2% nach der Optimierung entspricht einem leicht positiven Transfer. Dieser weist darauf hin, dass in mehr als 50% der Fälle ein positiver Transfer erreicht wird. Der Mittelwert liegt mit -0.1% leicht im Minus.

Tabelle 6.14: Ergebnisse der Optimierung von Parametereinstellungen für die gesamte Testreihe des *Potsdam* Datensatzes $\mathfrak{D}_{M_1}^{Pot}$ basierend auf der Analyse der Gesamtgenauigkeiten (Med.: Median; MW: Mittelwert; Min: Minimum; Max: Maximum; Std: Standardabweichung).

$OA[\%]$	Ausgangsparameter				Optimale Parameter			
	OA_{SS}	OA_{ST}	OA_{DA}	ΔOA_{DA}	OA_{SS}	OA_{ST}	OA_{DA}	ΔOA_{DA}
Med.	79.9	75.3	74.0	-0.8	80.0	75.3	76.0	0.2
MW	80.6	73.9	71.7	-2.2	80.8	74.0	74.0	-0.1
Min	76.2	44.5	33.1	-	76.4	44.0	46.8	-
Max	87.5	87.5	87.7	-	87.7	87.7	87.8	-
Std	3.4	7.6	9.0	-	3.4	7.6	7.7	-

Die Verteilung der ΔOA_{DA} Werte über die gesamte Testreihe vor und nach der Optimierung ist dem Perzentil-Plot aus Abbildung 6.10 zu entnehmen. Der Anteil der Tests mit einem positiven Transfer steigt von 32% vor der Optimierung auf 56% nach der Optimierung an. Bei 77% aller Tests ist ΔOA_{DA} besser als -1.0% . Das ergibt sich aus dem Perzentil-Wert an der Stelle $\Delta OA_{DA} = -1\%$ und Subtraktion dieses Wertes von 100% aller Tests. Analog erhält man, dass für ca. 25% der Tests eine Verbesserung in ΔOA_{DA} von mehr als 1% erreicht wird. Die Differenzkurve in Abbildung 6.10 zeigt, dass die Verbesserung der Werte über die Testreihe nach der Optimierung vor allem durch die Verringerung der Anzahl von Tests erreicht wurde, welche früher zu NT geführt haben. In dem Bereich von $\Delta OA_{DA} \in [-2\%..0\%]$ fiel der Anteil der Tests am stärksten um bis zu 25%.

Eine Analyse der DA Ergebnisse für einzelne Klassen mit den Genauigkeitsmaßen Vollständigkeit, Korrektheit und F1-Maß vor und nach der Optimierung gemittelt über die Testreihe ist in Abbildung 6.11 vorgestellt. Klassenspezifische Qualitätskriterien mit Ausnahme der Korrektheit für die Klasse *Versiegelte Fläche* haben ihre Werte für alle Klassen nach der Optimierung verbessert. Für die Klasse *Versiegelte Fläche* hat ein geringer Abfall der Korrektheit von 79.3% vor der Optimierung auf 79.0% nach der Optimierung stattgefunden (siehe Tabelle 6.15). Im Vergleich zu den Klassen *Versiegelte Fläche* und *Gebäude*, deren klassenspezifischen Genauigkeitswerte bei optimalen Parametern alle über 79% bzw. 88% liegen, zeigen die Klassen *Niedrige Vegetation* und *Baum* mit Ergebnissen über 65% bzw. 55% etwas schlechtere klassenspezifische Genauigkeiten. Ein mögliche Begründung dafür liegt in der Ausprägung der Vegetation. Bedingt durch die Bildflugzeit in der Herbstmitte (Tabelle 5.1) weisen die Bilder lückenhafte oder fehlende Belaubung der Bäume bzw. geringe Vitalität von Grasflächen auf (siehe Abbildung 5.1). Das führt unter anderem dazu, dass das vegetationsspezifische Merkmal NDVI dort schlechter ausgeprägt ist. Außerdem kommt es z.B. vor, dass die Stellen der fehlenden Belaubung der Bäume in Bilddaten charakteristische Merkmale der darunter liegenden Objekten aufweisen. Am schlechtesten wird die Klasse *Sonstiges* erkannt. Die Korrektheit liegt bei 22.9%, wohingegen die Vollständigkeit nur auf 9.6% kommt. Einerseits ist die Klasse *Sonstiges* per Definition (als Restklasse) sehr heterogen, sodass ihre charakteristischen Merkmale im Merkmalsraum relativ weit gestreut sind und sich mit den Clustern überlappen. Frühere Untersuchungen haben gezeigt [Paul et al., 2016], dass die Trainingsbeispiele von kleineren Klassen durch die größeren Klassen komplett oder teilweise übernommen werden, falls sich ihre Verteilung mit der Verteilung einer anderen Klasse stark überlappt (siehe auch Kapitel 4.5). Als Folge leidet die Qualität der Erkennung dieser Klasse. Andererseits ist diese Objektklasse in vielen Bildkacheln stark unterrepräsentiert. Bei 6

von 19 Kacheln in dem verwendeten Datensatz $\mathcal{D}_{U_1}^{Pot}$ liegt der Anteil der Pixel aus der Klasse *Sonstiges* bei unter 2.5% der Gesamtzahl aller Pixel im Bild. In manchen Fällen werden die Stichproben aus der Klasse *Sonstiges* nicht in die Trainingsdaten übernommen. Damit kann der Klassifikator die Verteilung dieser Klasse gar nicht (Verletzung der Annahme eines gleichen Labelraums) oder nicht gut genug anlernen. Das Problem könnte z.B. mit einem kleineren Wert der Rasterweite RW umgegangen werden.

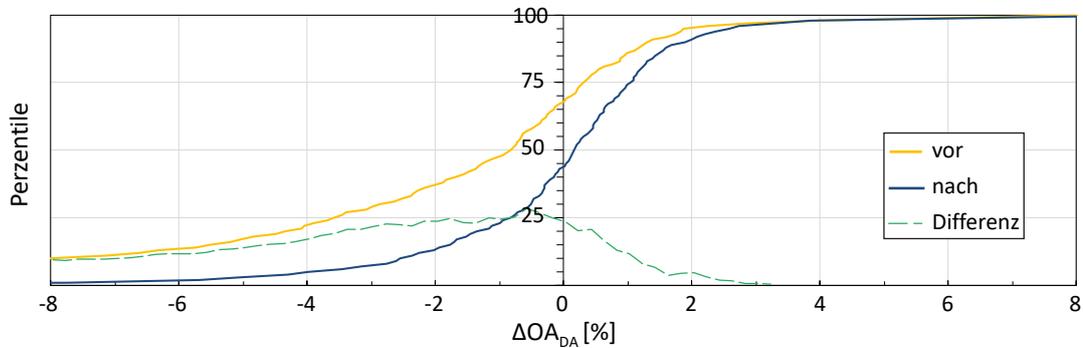


Abbildung 6.10: Perzentil-Plot mit den ΔOA_{DA} Ergebnissen der DA über die ganze Testreihe auf dem $\mathcal{D}_{U_1}^{Pot}$ Datensatz *vor* und *nach* Optimierung der Parameter. Die *Differenz* stellt den Unterschied zwischen den beiden Kurven dar.

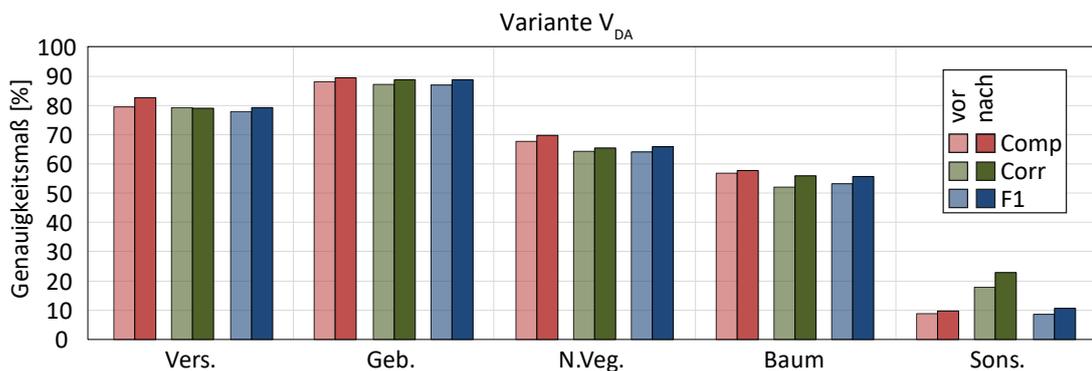


Abbildung 6.11: Mittlere klassenspezifische Genauigkeitsmaße Vollständigkeit (Comp), Korrektheit (Corr) und F1-Maß (F1) ermittelt auf dem $\mathcal{D}_{U_1}^{Pot}$ Datensatz nach der DA für alle Klassen *vor* und *nach* Optimierung der Parameter (Vers.: *Versiegelte Fläche*, Geb.: *Gebäude*, N.Veg.: *Niedrige Vegetation*, Baum: *Baum*, Sons.: *Sonstiges*; MW: Mittelwert). Exakte Werte sind in Tabelle 6.15 zusammengefasst.

Tabelle 6.15: Genauigkeitswerte für Vollständigkeit (Comp), Korrektheit (Corr) und F1-Maß (F1) für alle Klassen *vor* und *nach* Optimierung der Parameter aus Abbildung 6.11 (Vers.: *Versiegelte Fläche*, Geb.: *Gebäude*, N.Veg.: *Niedrige Vegetation*, Baum: *Baum*, Sons.: *Sonstiges*; MW: Mittelwert).

Variante V_{DA}		Vers.	Geb.	N.Veg.	Baum	Sons.	MW
vor	Comp [%]	79.5	88.2	67.7	56.9	8.9	60.2
	Corr [%]	79.3	87.1	64.3	52.0	17.8	60.1
	F1 [%]	77.9	87.0	64.2	53.2	8.7	58.2
nach	Comp [%]	82.6	89.5	69.6	57.7	9.6	61.8
	Corr [%]	79.0	88.7	65.4	55.8	22.9	62.4
	F1 [%]	79.3	88.8	65.8	55.6	10.5	60.0

6.2 Analyse der Prädiktion von negativem Transfer

In diesem Abschnitt wird die vorgeschlagene Methode zur Modifikation der Verteilungen der Quell- und Zieldomäne nach einem gleichen Muster unter Verwendung von a-priori Wissen aus der Quelldomäne zum Zweck der Prädiktion von NT analysiert. Die Analyse ist in Abhängigkeit von den verfolgten Zielen in drei Abschnitte unterteilt. Zunächst soll hier gezeigt werden, dass eine solche Modifikation der Verteilungen zu einer besseren Prädiktion von NT führt. Als Nächstes wird die vorgeschlagene Methode mit zwei weiteren alternativen Methoden verglichen. Zum Schluss wird ein Schwellwert zur Prädiktion von NT für die Experimente zur Evaluierung der vorgeschlagenen Methode zur DA ermittelt.

6.2.1 Verbesserung der Qualität der Prädiktion

6.2.1.1 Zielsetzung

Zunächst wird hier die vorgeschlagene Methode zur Prädiktion von NT aus Kapitel 4.4 überprüft, die auf einer Modifikation der Verteilungen aus Quell- und Zieldomäne nach dem gleichen Muster unter Verwendung von a-priori Wissen aus der Quelldomäne basiert. Das Ziel der Experimente ist zu zeigen, dass die Modifikation der Verteilungen die darauf folgende Schätzung der Diskrepanz zwischen den Domänen verbessern kann und somit zu einem besseren Merkmal zur Prädiktion von NT führt.

6.2.1.2 Durchführung der Experimente

Vorgehensweise bei der Untersuchung. Die Untersuchung des vorgeschlagenen Merkmals zur Prädiktion von NT basiert auf dem Vergleich zweier Szenarien auf demselben Datensatz (ohne bzw. mit der Modifikation der Verteilung). Zur Analyse der Qualität der Prädiktion von NT in jedem Szenario wird eine lineare Regression verwendet, um die lineare Abhängigkeit der Adaptionsgüte ΔOA_{DA} (Gleichung 5.7) von den ermittelten MMD -Werten ohne (d_{MMD}) bzw. mit (d_{MMD_m}) der Modifikation der Verteilung zu untersuchen. Die Berechnung von ΔOA_{DA} basiert auf Subtraktion OA_{ST} von OA_{DA} (Gleichung 5.7). Die Genauigkeiten OA_{ST} und OA_{DA} werden während der DA mit den optimierten Parametereinstellungen aus Tabelle 6.13 ermittelt. Zur Bestimmung der Genauigkeiten OA_{ST} und OA_{DA} wird die Gesamtmenge der Pixel mit zugehörigen Referenzlabels aus den Daten der Zieldomäne verwendet. Das Vorzeichen von ΔOA_{DA} weist dabei, gemäß der getroffenen Definition, auf einen positiven bzw. negativen Transfer hin. Zugleich liefern die MMD -Werte ein Distanzmaß d zwischen den Verteilungen der Daten der Quell- und Zieldomäne. Ausgehend von dem Distanzmaß wird ein Rückschluss auf den NT getroffen. Die Beziehung zwischen der abhängigen Variable ΔOA_{DA} und der unabhängigen Variable MMD bzw. MMD_m einer Testreihe wird im Rahmen der Analyse durch eine Regressionsgerade modelliert. Die Anpassungsgüte der ermittelten Regressionsgerade an die jeweiligen Datenpaare wird mittels des Bestimmtheitsmaßes R^2 (siehe Kapitel 5.3) bewertet. Das Szenario mit einem größeren

Tabelle 6.16: Übersicht über die Datensätze $\mathfrak{D}_{\mathfrak{M}_2}^{Vai}$, $\mathfrak{D}_{\mathfrak{M}_2}^{Pot}$ und $\mathfrak{D}_{\mathfrak{M}_2}^{3CITYDS}$, die im Rahmen der Analyse der Prädiktion von negativem Transfer in Kapitel 6.2 verwendet werden. Für die Datensätze wurden bestimmte Kacheln aus dem jeweiligen Testgebiet ausgewählt, deren Anzahl in Spalte *#Kacheln* zu finden ist. Die ausgewählten Kacheln sind hier entsprechend der numerischen Kodierung aus Abbildung 5.2 aufgelistet. Die Gesamtmenge der Tests für den zugehörigen Datensatz steht in Spalte *#Tests*.

Datensatz	#Kacheln	#Tests	Testgebiet	Kachel-Nrn.
$\mathfrak{D}_{\mathfrak{M}_2}^{Vai}$	15	225	Vaihingen	02, 04, 06, 08, 10, 12, 15, 21, 23, 27, 29, 31, 33, 34, 37
$\mathfrak{D}_{\mathfrak{M}_2}^{Pot} = \mathfrak{D}_{\mathfrak{M}_1}^{Pot}$	19	361	Potsdam	02_11, 02_13, 03_10, 03_12, 03_14, 04_11, 04_13, 04_15, 05_10, 05_12, 05_14, 06_07, 06_09, 06_11, 06_13, 06_15, 07_08, 07_10, 07_12
$\mathfrak{D}_{\mathfrak{M}_2}^{3CITYDS}$	12	144	Buxtehude	112, 121, 123, 132
			Hannover	212, 221, 223, 232
			Nienburg	312, 321, 323, 332

Wert von R^2 weist auf einen stärkeren linearen Zusammenhang der untersuchten Datenpaare (empirischer Korrelationskoeffizient r : $r^2 = R^2$) und soll somit zu einer besseren Prädiktion von NT führen.

Datensatz. Die experimentelle Untersuchung erfolgt auf dem *Potsdam* Datensatz $\mathfrak{D}_{\mathfrak{M}_2}^{Pot}$, der identisch zu $\mathfrak{D}_{\mathfrak{M}_1}^{Pot}$ aus Abschnitt 6.1.1.2 ist (siehe Tabelle 6.16).

Jedes Szenario wird mittels der Regressionsanalyse an einer Testreihe untersucht. Bei jedem Test aus der Testreihe wird eine Kachel aus dem verwendeten Datensatz $\mathfrak{D}_{\mathfrak{M}_2}^{Pot}$ als Quelldomäne und eine Kachel als Zieldomäne gewählt. Alle möglichen Kombinationen von Kacheln bilden eine Testreihe, wobei die Verwendung ein und derselben Kachel für Quell- und Zieldomäne möglich ist. Damit besteht die Testreihe für ein Experiment aus 361 einzelnen Tests (siehe Tabelle 6.16).

Quelle und Ziel. In dieser Untersuchung ist mit der Quelle S jene Kachel gemeint, an deren Daten der initiale Klassifikator trainiert wird. Unter dem Ziel T wird hingegen die Kachel verstanden, die zum Testen der DA verwendet wird. Die gelabelten Daten der Quelldomäne liefert a-priori Wissen zur Modifikation der Verteilungen der Quell- und Zieldomäne bei der Ermittlung von d_{MMD_m} .

Bewertungskriterium. Die Bewertung der beiden Szenarien erfolgt mittels des Bestimmtheitsmaßes R^2 und des empirischen Korrelationskoeffizienten r . Diese werden aus der Regression von ΔO_{ADA} in Bezug auf d_{MMD} bzw. d_{MMD_m} ermittelt. Die Modifikation der Verteilung (inklusive der automatischen Bestimmung von λ) wird gemäß der Beschreibung aus Kapitel 4.4 durchgeführt. Die Berechnung der MMD -Werte erfolgt für beide Szenarien gemäß der Beschreibung in Kapitel 2.3.

6.2.1.3 Ergebnisse

Die Ergebnisse zur Überprüfung der Hypothese, dass die vorgeschlagene Modifikation der Verteilung ein besseres Merkmal zur Prädiktion von NT liefern kann, sind in Abbildung 6.12 vorgestellt. Die Abbildung zeigt die Datenpaare von ΔO_{ADA} mit den entsprechenden MMD -Werten

für das jeweilige Szenario. Die ermittelten Regressionsgeraden sind als schwarze Linien eingezeichnet. Das Bestimmtheitsmaß für das Szenario ohne Modifikation der Verteilungen beträgt $R^2 = 0.177$ ($|r| = 42.1\%$). Für das Szenario mit Modifikation der Verteilungen steigt der Wert vom Bestimmtheitsmaß um 0.012 auf $R^2 = 0.189$ ($|r| = 43.5\%$). Das bedeutet, dass nur etwa 18% bzw. 19% der Streuung in den Daten in dem Szenario ohne bzw. mit Modifikation der Verteilungen durch das jeweilige Regressionsmodell erklärt werden kann. Nichtsdestotrotz weist der größere Wert von R^2 bei der vorgeschlagenen Methode auf einen stärkeren linearen Zusammenhang zwischen ΔOA_{DA} und d_{MMD_m} hin. Daraus lässt sich schließen, dass die Methode auf Basis von MMD mit Modifikation der Verteilungen zu einer etwas besseren Prädiktion von NT führen sollte, was die aufgestellte Hypothese bestätigen würde. Nun soll im nächsten Abschnitt die Qualität der Prädiktion von NT mittels der vorgeschlagenen Methode mit der Qualität von alternativen Verfahren verglichen werden.

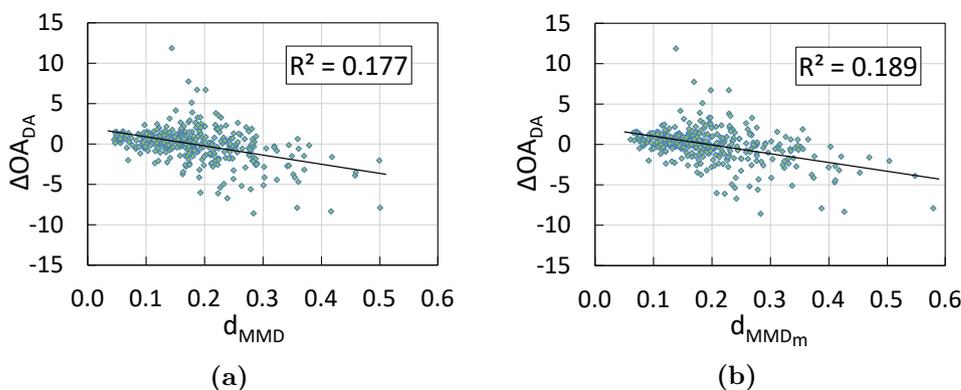


Abbildung 6.12: Ergebnisse der linearen Regressionsanalyse zwischen ΔOA_{DA} und einem Distanzmaß d auf dem $\mathcal{D}_{M_2}^{Pot}$ Datensatz bei der Untersuchung der Verbesserung der Diskrepanzschätzung für zwei Szenarien: (a) *ohne* und (b) *mit* Modifikation der Verteilungen. Die ermittelten Regressionsgeraden sind als schwarze Linien eingezeichnet. Die Anpassungsgüte der Daten an die jeweilige Regressionsgerade wird durch das Bestimmtheitsmaß R^2 ausgedrückt. Der größere Wert von R^2 bei der vorgeschlagenen Methode mit Modifikation der Verteilungen weist auf einen stärkeren Zusammenhang zwischen ΔOA_{DA} und d_{MMD_m} Werten hin. Diese Methode sollte damit zu einer besseren Prädiktion von NT führen.

6.2.2 Vergleich mit alternativen Verfahren

6.2.2.1 Zielsetzung

In diesem Abschnitt wird die im Kapitel 4.4 vorgeschlagene Methode zur Prädiktion von NT mit zwei alternativen Verfahren verglichen: mit der Methode auf Basis der ursprünglichen MMD -Metrik [Gretton et al., 2012] und mit der cvs [Bruzzone und Marconcini, 2010] (siehe Kapitel 3.1.6), die auf der Gesamtgenauigkeit OA_{CSV} nach der Rückwärtsadaptation als Distanzmetrik basiert. Das Ziel der Experimente ist also, die Verbesserung der Prädiktion mit der vorgeschlagenen Methode durch den Vergleich mit alternativen Methoden quantitativ auszuwerten.

6.2.2.2 Durchführung der Experimente

Vorgehensweise bei der Untersuchung. Die experimentelle Untersuchung besteht aus zwei Teilen. Um die Experimente beschreiben zu können, wird zunächst auf die verwendeten Distanzmaße formal eingegangen. Als Distanzmaß $d_{\mathfrak{S}}$ wird der Wert einer Metrik bezeichnet, der mit einer der folgenden Strategien $\mathfrak{S} \in \{CVS, MMD, MMD_m\}$ ermittelt wurde. Die Distanz für CVS wird mittels der Gesamtgenauigkeit OA_{CVS} nach Rückwärtsadaption durch $d_{CVS} = 100\% - OA_{CVS}$ definiert und kann als Differenz zu einer perfekten Klassifikation mit der Genauigkeit von 100% interpretiert werden. Die beiden restlichen Distanzen d_{MMD} und d_{MMD_m} werden gleich dem Diskrepanzwert der MMD -Schätzung nach der Anwendung der entsprechenden Strategie ohne und mit Modifikation der Verteilungen gesetzt. Dabei erfolgt die Modifikation der Verteilung (inklusive der automatischen Bestimmung von λ) gemäß der Beschreibung aus Kapitel 4.4 und die Berechnung der MMD -Werte gemäß Kapitel 2.3. Die ermittelten Distanzwerte $d_{\mathfrak{S}}$ werden anschließend zur Beurteilung der Ähnlichkeit zweier Domänen verwendet: je kleiner der Wert, desto höher die Ähnlichkeit.

Im ersten Teil der Untersuchung findet dann die Regressionsanalyse statt, bei der die empirische Korrelation r zwischen der Qualität der Adaption ΔOA_{DA} und den Werten $d_{\mathfrak{S}}$ der jeweiligen Distanzmetrik ermittelt und verglichen wird (analog zu der Vorgehensweise aus dem vorherigen Abschnitt). Im zweiten Teil werden die resultierenden Ergebnisse der DA nach der Prädiktion von NT verglichen. Um die Prädiktion von NT durchzuführen, wird zuerst ein optimaler Schwellwert $\tau_{\mathfrak{S}}$ mit Hilfe der ROC-Kurve für jede Strategie \mathfrak{S} bestimmt. Dieser Schwellwert wird auf jede ermittelte Distanz $d_{\mathfrak{S}}$ angewendet, um die Fälle von NT vorherzusagen. Ist NT nicht zu erwarten, wird die DA eingeleitet; andernfalls wird der Klassifikator aus der Quelldomäne unmittelbar auf die Zieldomäne angewandt ($OA_{DA} = OA_{ST}$). Damit gilt für $\Delta OA_{DA}^{\mathfrak{S}}$ nach der Prädiktion von NT mit der Strategie $\mathfrak{S} \in \{CVS, MMD, MMD_m\}$:

$$\Delta OA_{DA}^{\mathfrak{S}} = \begin{cases} OA_{DA} - OA_{ST} & \text{falls } d_{\mathfrak{S}} < \tau_{\mathfrak{S}} & \text{(positiver Transfer erwartet)} \\ 0 & \text{sonst} & \text{(negativer Transfer erwartet)} \end{cases}. \quad (6.1)$$

Bewertungskriterien. Zum Vergleich der Methoden mit Hilfe der Regressionsanalyse im ersten Teil der Untersuchung wird die Korrelation zwischen den Werten von ΔOA_{DA} und dem entsprechenden Distanzmaß $d_{\mathfrak{S}}$ einer der Metriken verwendet. Zur Bewertung der Ergebnisse werden das Bestimmtheitsmaß R^2 und der zugehörige empirische Korrelationskoeffizient r eingesetzt. Beim Vergleich der Ergebnisse der DA nach Prädiktion von NT im zweiten Teil der Untersuchung kommt die Genauigkeit OA_{DA} der Klassifikation der Zieldaten zum Einsatz.

Datensatz. Die experimentelle Untersuchung findet auf dem Potsdam Datensatz \mathfrak{D}_{12}^{Pot} statt. Detaillierte Informationen zu dem Datensatz sind in der Tabelle 6.16 vorgestellt.

In dem Experiment findet die Untersuchung an einer Testreihe statt. Bei jedem Test aus der Testreihe wird eine Kachel aus dem verwendeten Datensatz \mathfrak{D}_{12}^{Pot} als Quelldomäne und eine als Zieldomäne gewählt. Wie schon in Kapitel 6.1.1.2 erwähnt, bilden auch hier alle möglichen

Kombinationen von Kacheln eine Testreihe, wobei die Verwendung derselben Kachel für Quell- und Zieldomäne möglich ist.

6.2.2.3 Ergebnisse

Regressionsanalyse. Hier wird der vorgeschlagene Ansatz mit den Ergebnissen der ursprünglichen MMD und mit der Distanzmetrik auf Basis der Gesamtgenauigkeit OA_{CVS} nach der Rückwärtsadaptation gemäß CVS verglichen. Die Ergebnisse sind in Abbildung 6.13 vorgestellt. Das Bestimmtheitsmaß für die CVS beträgt nur $R^2 = 0.012$. Das heißt, dass nur etwa 1% der Streuung in den Daten durch das Regressionsmodell erklärt werden kann. Für die beiden auf MMD basierenden Strategien steigt der Wert vom Bestimmtheitsmaß auf $R^2 = 0.177$ für $\mathfrak{S} = MMD$ und $R^2 = 0.189$ für $\mathfrak{S} = MMD_m$. Damit können etwa 18% bzw. 19% der Streuung in den Daten durch das jeweilige Regressionsmodell erklärt werden. Der zugehörige empirische Korrelationskoeffizient liegt bei $|r| = 10.9\%$ für $\mathfrak{S} = CVS$, bei $|r| = 42.1\%$ für $\mathfrak{S} = MMD$ und bei $|r| = 43.5\%$ für $\mathfrak{S} = MMD_m$. Somit sind die erzielten Korrelationen für alle Strategien niedrig (CVS) bis mittelmäßig (MMD, MMD_m) zu bewerten. Nichtsdestotrotz zeigt die Distanzmetrik auf Basis der vorgeschlagenen Modifikation der Verteilungen die höchste Korrelation unter den untersuchten alternativen Verfahren.

Vergleich der Ergebnisse nach Prädiktion von negativem Transfer. Zum Vergleich der Ergebnisse nach Prädiktion von NT mit der jeweiligen Strategie $\mathfrak{S} \in \{CVS, MMD, MMD_m\}$ werden zunächst die Schwellwerte $\tau_{\mathfrak{S}}$ bestimmt. Die Bestimmung eines optimalen Schwellwerts erfolgt in diesem Experiment unter Berücksichtigung der Klassenlabels sowohl in Quell- als auch in Zieldomäne, um die volle Prädiktionsleistung der jeweiligen Strategie ausnutzen zu können. Für jeden möglichen Schwellwert τ werden die Fälle von positivem bzw. negativem Transfer anhand der jeweiligen Distanz $d_{\mathfrak{S}}$ bestimmt und durch die Fälle vom tatsächlichen positiven bzw. negativen Transfer (anhand des Vorzeichens von ΔOA_{DA}) validiert. Jeder möglicher Schwellwert führt somit zu einer binären Klassifikationsentscheidung, für die die Werte der True-Positive-Rate TPR und der False-Positive-Rate FPR ermittelt werden. Dabei ist die Anzahl der zu untersuchenden Schwellwerte durch die Anzahl der ermittelten Distanzen $d_{\mathfrak{S}}$ und somit durch die Anzahl der Tests (361) in der Testreihe beschränkt. Alle durch die Wahl des Schwellwertes entstandenen Werte von TPR und FPR werden in der ROC-Kurve erfasst. Die ROC-Kurve wird hier zur Auswahl des optimalen Schwellwerts $\tau_{\mathfrak{S}}$ eingesetzt. Als optimal wird ein Schwellwert mit einer möglichst hohen TPR und möglichst niedrigen FPR eingesehen. Die ROC-Kurven inklusive Optima für die jeweilige Strategie sind in Abbildung 6.14a vorgestellt. Die beiden MMD-basierten Metriken zeigen einen ähnlichen Verlauf und eine ähnliche Lage der Optima bei TPR = 63% und FPR = 29% für MMD und bei TPR = 71% und FPR = 34% für MMD_m. Das Ergebnis der CVS ist sichtbar schlechter. Die anhand der ROC-Kurve ermittelten Schwellwerte sind: $\tau_{MMD}^{ROC} = 0.169$, $\tau_{MMD_m}^{ROC} = 0.191$ und $\tau_{CVS}^{ROC} = 20.05\%$. Die Ergebnisse der Prädiktion von NT mit der jeweiligen Strategie gemäß der Gleichung 6.1 sind in Abbildung 6.14b präsentiert. Anhand der entsprechenden Distanzmetrik wurde für 44%, 52% bzw. 45% der Tests ein NT mit der CVS, MMD bzw. MMD_m Strategie vorhergesagt, davon hätten 16% (von 44%), 31% (von 52%) bzw. 28% (von 45%) tatsächlich zum

NT und 28%, 21% bzw. 17% zu positivem Transfer geführt. Eine Verbesserung der ΔOA_{DA} von mehr als 2% wurde in etwa 12% der Fälle mit der MMD und der MMD_m Strategie erzielt. Mit den beiden Strategien MMD und MMD_m wurde ein positiver Transfer über die ganze Testreihe von $\Delta OA_{DA}^{MMD} = 0.2\%$ bzw. $\Delta OA_{DA}^{MMD_m} = 0.3\%$ erreicht, welcher einer Verbesserung von 0.3% bzw. 0.4% im Vergleich zu dem Wert $\Delta OA_{DA} = -0.1\%$ vor der Prädiktion entspricht. Die vorgeschlagene MMD_m -basierende Strategie ist somit bei der Genauigkeit der Vorhersage gegenüber den alternativen Verfahren leicht im Vorteil. Trotzdem liefert auch die vorgeschlagene Methode mit der Korrelation von nur $|r| = 43.4\%$ zwischen ΔOA_{DA} und d_{MMD_m} und der leichten Verbesserung der Genauigkeit um 0.4% keine zufriedenstellenden Ergebnisse zur Prädiktion von NT für den untersuchten Datensatz.

6.2.3 Schwellwert zur Prädiktion von negativem Transfer

6.2.3.1 Zielsetzung

In diesem Abschnitt wird ein Schwellwert für die vorgeschlagene Methode zur Prädiktion von NT ermittelt und anschließend zur Bewertung der Prädiktion verwendet. Es wird im Rahmen dieser Arbeit für einen realen DA Einsatz vorausgesetzt, dass keine gelabelten Daten in der Zieldomäne zur Verfügung stehen. Aus diesem Grund kann die Bestimmung eines Schwellwerts zur Prädiktion von NT mit Hilfe der ROC-Kurve auf die Weise aus dem vorherigen Abschnitt 6.2.2 für die nachfolgende Evaluierung nicht angewendet werden. Das Ziel dieser Untersuchung ist also, einen optimalen globalen Schwellwert $\tau_{MMD_m}^{Pred}$ zur Prädiktion von NT mit der vorgeschlagenen Methode ohne Berücksichtigung der Labels aus der zu klassifizierenden Zieldomäne zu bestimmen.

6.2.3.2 Durchführung der Experimente

Vorgehensweise bei der Untersuchung. Zur Prädiktion von NT mit der vorgeschlagenen Methode wird ein globaler Schwellwert $\tau_{MMD_m}^{Pred}$ auf die jeweilige ermittelte MMD -Distanz gemäß Gleichung 6.1 angewendet. Die Verwendung eines globalen Schwellwerts setzt keine Verfügbarkeit der Labels in der Zieldomäne voraus. Zur Bestimmung des Schwellwerts $\tau_{MMD_m}^{Pred}$ werden optimale Schwellwerte von drei Datensätzen untersucht, die analog zu Kapitel 6.2.2.2 mit Hilfe der ROC-Kurven ermittelt werden. Der globale Schwellwert $\tau_{MMD_m}^{Pred}$ wird dann als Mittelwert aus den drei mit Hilfe der ROC-Kurve für den jeweiligen Datensatz ermittelten optimalen Schwellwerten bestimmt. Damit weist $\tau_{MMD_m}^{Pred}$ die kleinste mittlere quadratische Abweichung in Relation zu dem optimalen Schwellwert aus dem jeweiligen Datensatz auf. Die im Rahmen dieser Untersuchung verwendeten Datensätze unterscheiden sich dabei von den Datensätzen, die in Kapitel 6.3 und Kapitel 6.4 zur Evaluierung der DA verwendet werden. Für einen praktischen Einsatz der DA mit der vorgeschlagenen Methode zur Prädiktion von NT kann der Schwellwert auf ähnliche Weise mit Hilfe der verfügbaren Trainingsdaten (aus früheren Projekten bzw. der Quelle) ermittelt werden.

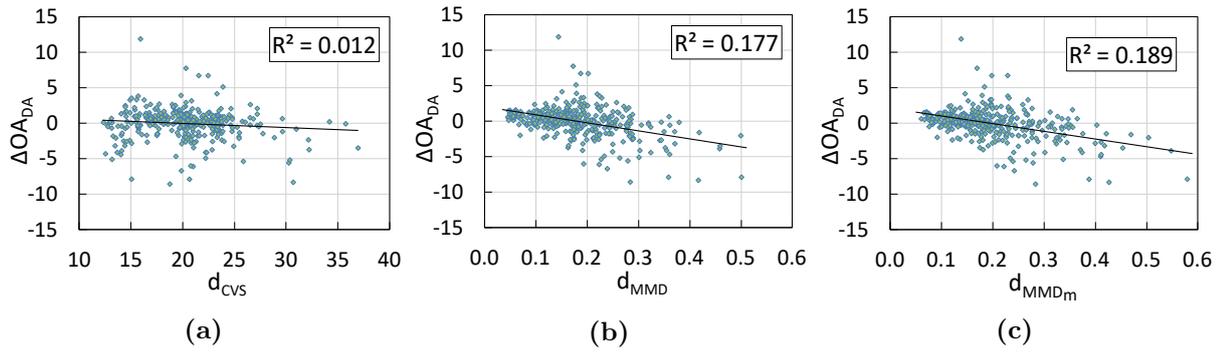


Abbildung 6.13: Ergebnisse der linearen Regression auf dem Datensatz $\mathfrak{D}_{\mathcal{M}_2}^{Pot}$ (siehe Tabelle 6.16) mit 3 unterschiedlichen Strategien: *CVS* (a), *MMD* (b) und *MMD_m* (c); (b) und (c) sind identisch zu Abbildung 6.12. Die ermittelten Regressionsgeraden sind als schwarze Linien eingezeichnet. Anpassungsgüte der Daten an die jeweilige Regressionsgerade wird durch das Bestimmtheitsmaß R^2 ausgedrückt. Das Bestimmtheitsmaß weist auf die Stärke der Korrelation zwischen den untersuchten Variablen hin: je größer R^2 , desto stärker der linearer Zusammenhang.

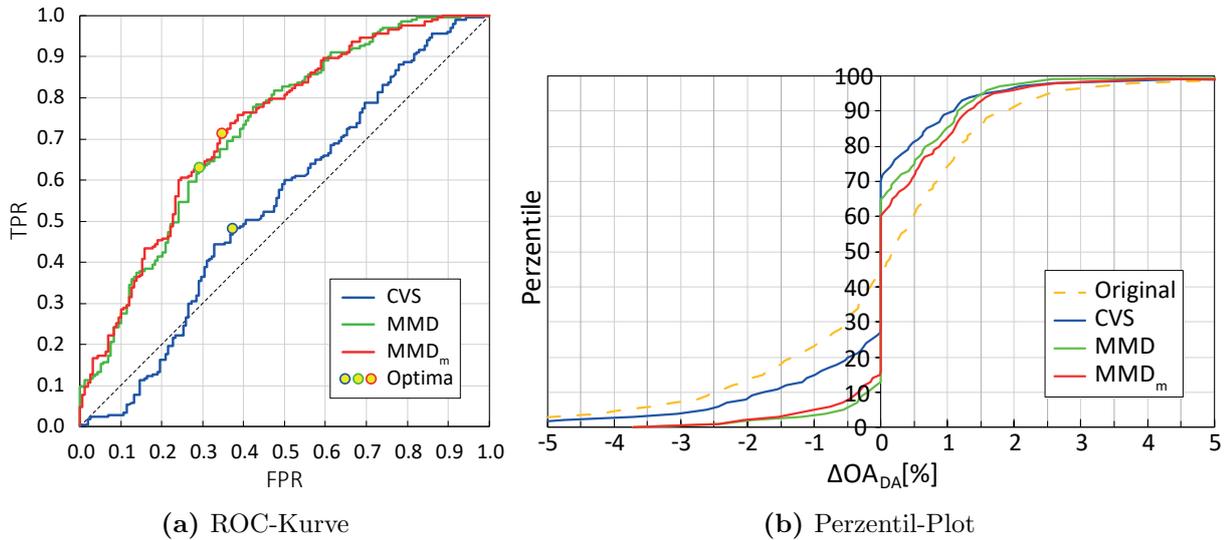


Abbildung 6.14: Ergebnisse des Vergleichs von drei Strategien zur Prädiktion von NT auf dem Potsdam Datensatz $\mathfrak{D}_{\mathcal{M}_2}^{Pot}$: (a) ROC-Kurven zur Ermittlung des optimalen Schwellwertes $\tau_{\mathfrak{G}}^{ROC}$; (b) Perzentil-Plots der Ergebnisse von ΔOA_{DA} vor (Original) und nach der Prädiktion von NT (vgl. Tabelle 6.17).

Tabelle 6.17: Mittelwerte der Genauigkeiten OA_{DA} , ΔOA_{DA} vor und nach der Prädiktion von NT sowie Verbesserung von ΔOA_{DA} durch die Prädiktion von NT für die jeweilige Strategie. Die Genauigkeitswerte vor der Prädiktion von NT entsprechen den Ergebnissen der DA (siehe Tabelle 6.14) auf demselben Satz von Bildkacheln des Testgebiets *Potsdam*.

Strategie	$\tau_{\mathfrak{G}}^{ROC}$	Vor Prädiktion		Nach Prädiktion		Verbesserung ($\Delta OA_{DA}^{\mathfrak{G}} - \Delta OA_{DA}$) [%]
		OA_{DA} [%]	ΔOA_{DA} [%]	$OA_{DA}^{\mathfrak{G}}$ [%]	$\Delta OA_{DA}^{\mathfrak{G}}$ [%]	
$\mathfrak{G} = CVS$	20.05%	74.0	-0.1	73.9	-0.1	0.0
$\mathfrak{G} = MMD$	0.169	74.0	-0.1	74.3	0.2	0.3
$\mathfrak{G} = MMD_m$	0.191	74.0	-0.1	74.3	0.3	0.4

Datensatz. Zur Analyse im Rahmen der Bestimmung einer geeigneten Einstellung für $\tau_{\text{MMD}_m}^{\text{Pred}}$ werden die Datensätze $\mathfrak{D}_{\mathcal{U}_2}^{\text{Vai}}$, $\mathfrak{D}_{\mathcal{U}_2}^{\text{Pot}}$ und $\mathfrak{D}_{\mathcal{U}_2}^{\text{3CITYDS}}$ verwendet. Detaillierte Informationen zu dem jeweiligen Datensatz sind in der Tabelle 6.16 zu finden.

Bei jedem Test im Rahmen der Untersuchung wird eine Kachel aus dem jeweiligen Datensatz als Quelldomäne und eine Kachel als Zieldomäne gewählt. Alle mögliche Kombinationen von Kacheln bilden eine Testreihe, wobei wie auch schon in Kapitel 6.2.1 und 6.2.2 die Verwendung derselben Kachel für Quell- und Zieldomäne möglich ist.

6.2.3.3 Ergebnisse

Vor der Ermittlung des globalen Schwellwerts werden zunächst die Ergebnisse der Regressionsanalyse zwischen der ΔO_{DA} und dem Distanzmaß MMD_m für alle drei Datensätze analysiert (siehe Abbildung 6.15). Das Bestimmtheitsmaß beträgt $R^2 = 0.025$ für *Vaihingen* ($\mathfrak{D}_{\mathcal{U}_2}^{\text{Vai}}$), $R^2 = 0.188$ für *Potsdam* ($\mathfrak{D}_{\mathcal{U}_2}^{\text{Pot}}$) und $R^2 = 0.042$ für den *3CITYDS* ($\mathfrak{D}_{\mathcal{U}_2}^{\text{3CITYDS}}$) Datensatz. Der zugehörige Korrelationskoeffizient liegt bei $|r| = 15.8\%$, 43.4% bzw. bei 20.5% für den jeweiligen Datensatz. Damit ist der Zusammenhang zwischen den Variablen ΔO_{DA} und d_{MMD_m} nur als gering bis mittelhoch zu bewerten.

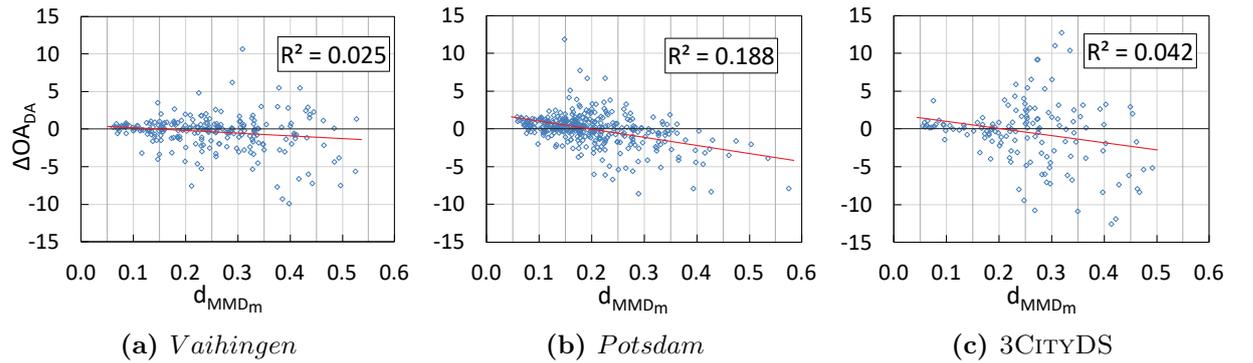


Abbildung 6.15: Ergebnisse der linearen Regressionsanalyse für ΔO_{DA} und MMD_m auf den Datensätzen $\mathfrak{D}_{\mathcal{U}_2}^{\text{Vai}}$, $\mathfrak{D}_{\mathcal{U}_2}^{\text{Pot}}$ und $\mathfrak{D}_{\mathcal{U}_2}^{\text{3CITYDS}}$. Die ΔO_{DA} Werte wurden nach der DA mit den optimalen Parametern aus Tabelle 6.13 ermittelt.

Anschließend wurde mit Hilfe der ROC-Kurve ein optimaler Schwellwert für den jeweiligen Datensatz ermittelt. Der jeweilige optimale Schwellwert τ^{ROC} liegt bei 0.241 für den *Vaihingen*, 0.191 für den *Potsdam* und bei 0.273 für den *3CITYDS* Datensatz. Als Mittelwert daraus ergibt sich $\tau_{\text{MMD}_m}^{\text{Pred}} = 0.235$. Dieser Wert repräsentiert den gesuchten globalen Schwellwert zur Prädiktion von NT. Der ermittelte Schwellwert $\tau_{\text{MMD}_m}^{\text{Pred}}$ weist somit die kleinste mittlere quadratische Abweichung in Relation zu den optimalen Schwellwerten τ^{ROC} aus dem jeweiligen Datensatz auf. Die Ergebnisse der Prädiktion von NT mit dem ermittelten globalen Schwellwert $\tau_{\text{MMD}_m}^{\text{Pred}} = 0.235$ für dieselben Datensätze (d.h. für die Datensätze, mit deren Hilfe $\tau_{\text{MMD}_m}^{\text{Pred}}$ ermittelt wurde) sind in Tabelle 6.18 vorgestellt. Durch die Anwendung der vorgeschlagenen Strategie zur Prädiktion von NT und des Schwellwerts $\tau_{\text{MMD}_m}^{\text{Pred}}$ hat sich der Mittelwert über die Genauigkeiten O_{DA} , die für die Tests einer Testreihe erzielt wurden, gegenüber dem Mittelwert vor der Prädiktion überall geringfügig verbessert: um 0.3% für den *Vaihingen* und jeweils um 0.4% für den *Potsdam* und den

3CITYDS Datensatz. Damit wurde für den *Potsdam* Datensatz im Durchschnitt ein positiver Transfer von 0.3% erreicht. Für den 3CITYDS Datensatz ergab sich im Mittel kein Unterschied ($\Delta OA_{DA}^{Pred} = 0.0\%$). Für den *Vaihingen* Datensatz blieb der Durchschnitt von ΔOA_{DA} trotz einer Verbesserung von -0.4% auf -0.1% im negativen Bereich.

Tabelle 6.18: Ergebnisse der Prädiktion von NT mit dem ermittelten globalen Schwellwert $\tau_{MMD_m}^{Pred} = 0.235$ für drei Datensätze: $\mathfrak{D}_{\mathfrak{M}_2}^{Vai}$, $\mathfrak{D}_{\mathfrak{M}_2}^{Pot}$ und $\mathfrak{D}_{\mathfrak{M}_2}^{3CITYDS}$. Die Tabelle zeigt Mittelwerte der Genauigkeiten über die Testreihe sowie die Verbesserung von ΔOA_{DA} vor und nach der Prädiktion. Die Genauigkeitswerte vor der Prädiktion von NT wurden nach der DA mit den optimalen Parametern aus Tabelle 6.13 ermittelt.

Datensatz	Vor Prädiktion		Nach Prädiktion mit $\tau_{MMD_m}^{Pred}$		Verbesserung ($\Delta OA_{DA}^{Pred} - \Delta OA_{DA}$)[%]
	OA_{DA} [%]	ΔOA_{DA} [%]	OA_{DA}^{Pred} [%]	ΔOA_{DA}^{Pred} [%]	
<i>Vaihingen</i> $\mathfrak{D}_{\mathfrak{M}_2}^{Vai}$	80.5	-0.4	80.8	-0.1	0.3
<i>Potsdam</i> $\mathfrak{D}_{\mathfrak{M}_2}^{Pot}$	74.0	-0.1	74.3	0.3	0.4
3CITYDS $\mathfrak{D}_{\mathfrak{M}_2}^{3CITYDS}$	69.1	-0.4	69.5	0.0	0.4

6.2.4 Diskussion

Die vorgestellten Ergebnisse belegen die in Kapitel 4.4 aufgestellte Hypothese, nach der die vorgeschlagene Modifikation der Verteilung die darauf folgende Schätzung der Diskrepanz zwischen den Domänen mit Hilfe der *MMD*-Metrik verbessern kann und somit zu einem besseren Merkmal zur Prädiktion von NT im Vergleich zu den alternativen Verfahren führt. Bei der Regressionsanalyse von ΔOA_{DA} auf ein Distanzmaß $d_{\mathfrak{G}}$ stieg das Bestimmtheitsmaß mit der vorgeschlagenen Methode um 0.177 bzw. um 0.012 auf $R^2 = 0.189$ gegenüber der CVS bzw. der ursprünglichen *MMD*-Methode ohne Modifikation der Verteilung. Es ergibt sich daraus für die vorgeschlagene Methode der höchste Wert für den empirischen Korrelationskoeffizienten zwischen ΔOA_{DA} und MMD_m von $|r| = 43.5\%$. Allerdings deutet dieser Wert nur auf einen mittelgroßen linearen Zusammenhang zwischen den beiden Variablen hin, der keine zufriedenstellende Prädiktionsleistung für NT erwarten lässt.

Bei dem Vergleich der vorgeschlagenen Methode zur Prädiktion von NT mit zwei alternativen Verfahren auf Basis der CVS und der ursprünglichen *MMD*-Metrik haben die beiden auf *MMD*-basierenden Verfahren deutlich bessere Ergebnisse erzielt. Mit den beiden Methoden wurde im Durchschnitt ein positiver Transfer von 0.2% für *MMD* bzw. 0.3% für MMD_m über die Testreihe erreicht. Damit ist die Genauigkeit der Vorhersage von NT mit der vorgeschlagenen Methode leicht im Vorteil. Die Anwendung der vorgeschlagenen Methode führt zu einer durchschnittlichen Verbesserung der ΔOA_{DA} gegenüber dem Wert von -0.1% vor der Prädiktion um 0.4% auf 0.3% nach Prädiktion. Dabei liegt die Erkennungsrate (Vollständigkeit) TPR der Prädiktion von NT auf Basis eines optimalen Schwellwerts, der nur unter der Kenntnis der Labels aus der Zieldomäne bestimmt werden kann, bei 71% mit einer Fehlerrate FPR von 34% (siehe Abschnitt 6.2.2.3). Wie erwartet, stellen die Erkennungsrate und Fehlerrate kein zufriedenstellendes Ergebnis dar. Durch die Verwendung eines globalen Schwellwerts $\tau_{MMD_m}^{Pred}$ muss dieser nicht erneut für jeden Datensatz unter Verwendung der Labels in der Zieldomäne, die nicht zur Verfügung stehen,

bestimmt werden. Es muss allerdings wegen der Abweichung vom optimalen Schwellwert eine mögliche Reduktion der Qualität der Entscheidung in Kauf genommen werden.

Der globale Schwellwert zur Prädiktion von NT mit der vorgeschlagenen Methode wurde als Mittelwert der optimalen Schwellwerte auf Basis von drei Testdatensätzen ermittelt und beträgt $\tau_{\text{MMD}_m}^{\text{Pred}} = 0.235$. Der ermittelte Wert weist somit kleinste mittlere quadratische Abweichung in Relation zu optimalen Schwellwerten aus der jeweiligen Verteilung. Die hier gezeigten Ergebnisse zeigen, dass mit der vorgeschlagenen Methode zur Prädiktion von NT und dem ermittelten Schwellwert eine Verbesserung der Genauigkeit erzielt werden kann: für alle drei Testdatensätze wurde die durchschnittliche Genauigkeit ΔOA_{DA} um mindestens 0.3% nach der Prädiktion verbessert. Der ermittelte Schwellwert $\tau_{\text{MMD}_m}^{\text{Pred}} = 0.235$ wird nachfolgend zur Prädiktion von NT im Rahmen der DA eingesetzt.

6.3 Evaluierung der Domänenadaptation

6.3.1 Zielsetzung

Die Experimente in diesem Kapitel haben zum Ziel, die Leistungsfähigkeit des entwickelten Ansatzes zur DA, d.h. die Qualität der Anpassung an neue Szenen, unter realen Bedingungen zu evaluieren. Dabei wird die Prädiktion von NT hier nicht angewandt. Der Hintergrund dieser Untersuchung liegt in der Überprüfung der in der Einleitung aufgestellten Forschungsfrage, ob nämlich ein Transfer zwischen den unterschiedlichen Gebieten unter der Anwendung von DA möglich ist und ob der Genauigkeitsverlust gegenüber einem erneut anhand von gelabelten Trainingsdaten angelernten Modell dank dem entwickelten DA Ansatz klein gehalten werden kann.

6.3.2 Durchführung der Experimente

Vorgehensweise bei der Evaluierung. Zum Zwecke der Evaluierung der DA werden alle fünf Testgebiete (*Vaihingen*, *Potsdam*, *Buxtehude*, *Hannover* und *Nienburg*) verwendet, aus denen verschiedene Datensätze gebildet werden. Folglich weisen diese Datensätze Unterschiede in Bezug auf die Aufnahmesensorik, Lichtverhältnisse, saisonale Effekte und Bodenpixelgröße auf, die je nach Datensatz unterschiedlich stark ausgeprägt sind. Sie stellen damit eine solide Grundlage zur Evaluierung der DA dar.

Zur Evaluierung werden die im Abschnitt 6.1 ermittelten optimierten Parametereinstellungen verwendet, welche in der Tabelle 6.13 zusammengefasst sind. Die Bildkacheln aus dem Testgebiet *Vaihingen* weisen im Vergleich zu den anderen Testgebieten eine kleinere Größe auf. Um die Anzahl der extrahierten Stichproben (Trainings- sowie Testdaten) aus den Bildkacheln des

Tabelle 6.19: Übersicht über die Datensätze $\mathcal{D}_{\mathcal{U}_3}^{Vai}$, $\mathcal{D}_{\mathcal{U}_3}^{Pot}$, $\mathcal{D}_{\mathcal{U}_3}^{3CITYDS}$, $\mathcal{D}_{\mathcal{U}_3}^{POOL2}$, $\mathcal{D}_{\mathcal{U}_3}^{POOL5}$, die bei der Evaluierung der DA verwendet werden. Für die Datensätze wurden bestimmte Kacheln aus dem jeweiligen Testgebiet ausgewählt, deren Anzahl in Spalte *#Kacheln* zu finden ist. Die ausgewählten Kacheln sind hier entsprechend der Kodierung aus Abbildung 5.2 aufgelistet. Die Gesamtmenge der Tests für den zugehörigen Datensatz steht in Spalte *#Tests*.

Datensatz	#Kacheln	#Tests	Testgebiet	Kachel-Nrn.
$\mathcal{D}_{\mathcal{U}_3}^{Vai}$	18	324	Vaihingen	01, 03, 05, 07, 11, 13, 14, 16, 17, 20, 22, 24, 26, 28, 30, 32, 35, 38
$\mathcal{D}_{\mathcal{U}_3}^{Pot}$	19	361	Potsdam	02_10, 02_12, 02_14, 03_11, 03_13, 04_10, 04_12, 04_14, 05_11, 05_13, 05_15, 06_08, 06_10, 06_12, 06_14, 07_07, 07_09, 07_11, 07_13
$\mathcal{D}_{\mathcal{U}_3}^{3CITYDS}$	15	225	Buxtehude	111, 113, 122, 131, 133
			Hannover	211, 213, 222, 231, 233
			Nienburg	311, 313, 322, 331, 333
$\mathcal{D}_{\mathcal{U}_3}^{POOL2}$	37	1369	Vaihingen	01, 03, 05, 07, 11, 13, 14, 16, 17, 20, 22, 24, 26, 28, 30, 32, 35, 38
			Potsdam	02_10, 02_12, 02_14, 03_11, 03_13, 04_10, 04_12, 04_14, 05_11, 05_13, 05_15, 06_08, 06_10, 06_12, 06_14, 07_07, 07_09, 07_11, 07_13
$\mathcal{D}_{\mathcal{U}_3}^{POOL5}$	52	2704	Vaihingen	01, 03, 05, 07, 11, 13, 14, 16, 17, 20, 22, 24, 26, 28, 30, 32, 35, 38
			Potsdam	02_10, 02_12, 02_14, 03_11, 03_13, 04_10, 04_12, 04_14, 05_11, 05_13, 05_15, 06_08, 06_10, 06_12, 06_14, 07_07, 07_09, 07_11, 07_13
			Buxtehude	111, 113, 122, 131, 133
			Hannover	211, 213, 222, 231, 233
			Nienburg	311, 313, 322, 331, 333

Testgebietes *Vaihingen* an die Anzahl der Stichproben aus den anderen Testgebieten anzupassen, wird der Parameter der Rasterweite für *Vaihingen* auf $RW = 20$ reduziert. Die restlichen Parameter werden ohne Änderung für alle Testgebiete übernommen.

Datensätze. Die Evaluierung der DA erfolgt auf den fünf folgenden Datensätzen: $\mathcal{D}_{\mathcal{U}_3}^{Vai}$, $\mathcal{D}_{\mathcal{U}_3}^{Pot}$, $\mathcal{D}_{\mathcal{U}_3}^{3CITYDS}$, $\mathcal{D}_{\mathcal{U}_3}^{POOL2}$, $\mathcal{D}_{\mathcal{U}_3}^{POOL5}$. Dabei ist die Menge der verwendeten Bildkacheln aus dem Testgebiet *Potsdam*, die im Datensatz $\mathcal{D}_{\mathcal{U}_1}^{Pot}$ zur Optimierung der Parametereinstellungen verwendet wurde (siehe Kapitel 6.1), zu der Menge der Bildkacheln $\mathcal{D}_{\mathcal{U}_3}^*$ in dem jeweiligen Evaluierungsdatensatz in diesem Abschnitt disjunkt ($\mathcal{D}_{\mathcal{U}_1}^{Pot} \cap \mathcal{D}_{\mathcal{U}_3}^* = \emptyset$). Detaillierte Informationen zu den Datensätzen sind in der Tabelle 6.19 zu finden.

In dem jeweiligen Experiment findet die Untersuchung an einer Testreihe statt. Bei jedem Test der Testreihe wird eine Kachel aus dem verwendeten Datensatz als Quelldomäne und eine Kachel als Zieldomäne gewählt. Alle möglichen Kombinationen von Kacheln bilden eine Testreihe, wobei auch die Verwendung derselben Kachel für Quell- und Zieldomäne möglich ist.

Quelle und Ziel. Im Kontext der DA wird hier unter Quelle S die Kachel gemeint, an deren Daten der initiale Klassifikator trainiert wird. Als Ziel T wird die Kachel bezeichnet, die zum Testen der DA zum Einsatz kommt. Im Rahmen dieser Testreihen stehen Labels nur für die Daten aus der Quelldomäne zur Verfügung. Die Klassenlabels für die Daten aus der Zieldomäne werden nur zur Auswertung der Genauigkeiten verwendet.

Ermittlung der Genauigkeiten. Mit Hilfe der Rasterweite RW wird eine Menge der Stichproben aus der Quelldomäne und der Zieldomäne extrahiert. Die extrahierten Stichproben der

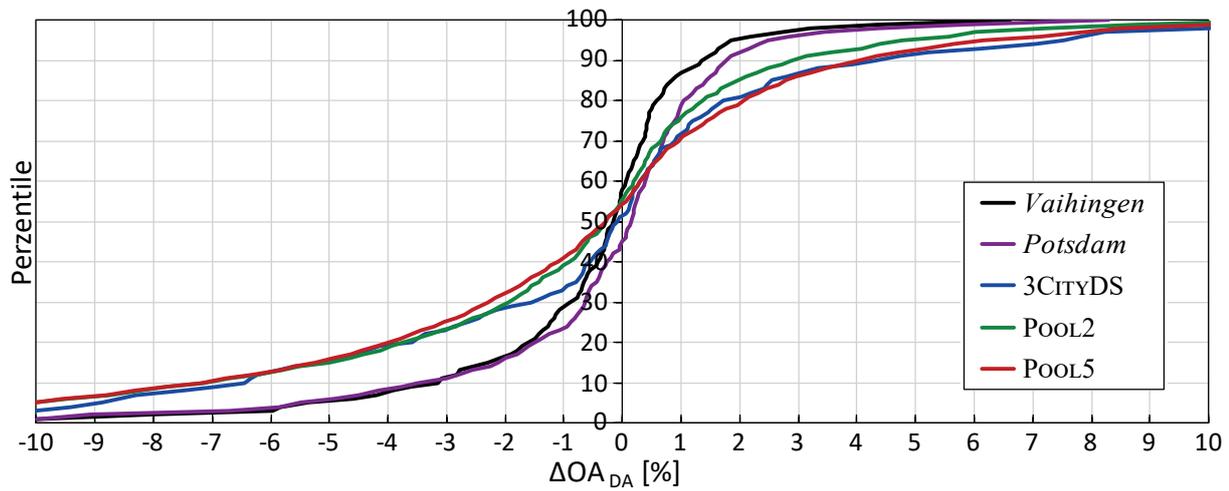
jeweiligen Quelldomäne (Merkmalsvektoren und zugehörige Klassenlabels) bilden ein Trainingsdatensatz, an dem der initiale Klassifikator antrainiert wird. Die extrahierten Stichproben und die zugehörigen Labels der Zieldomäne werden zum Training der LR in der Variante V_{TT} verwendet, während dieselben Stichproben ohne Labels zur Anpassung des Klassifikators mittels der DA eingesetzt werden. Zur Ermittlung der Gesamtgenauigkeit OA_{TT} wird die Menge der Stichproben der Zieldomäne (Merkmalsvektoren und zugehörige Klassenlabels) genommen, die nicht fürs Training der LR verwendet werden. Im Gegensatz dazu erfolgt die Ermittlung der Genauigkeiten OA_{ST} und OA_{DA} auf der Gesamtmenge der Stichproben und Referenzlabels der Zieldomäne.

Auswertung. Der Fokus bei der Auswertung der Ergebnisse liegt auf der Genauigkeit der Adaption, die durch die Werte von OA_{DA} , ΔOA_{DA} und ΔOA_{TD} ausgedrückt wird (siehe Kapitel 5.3). Dabei beschreibt der Wert von OA_{DA} die allgemeine Genauigkeit des adaptierten Klassifikators. Der Qualitätsmaß ΔOA_{DA} stellt eine Änderung der Genauigkeit aufgrund der Anwendung von DA als Differenz der Genauigkeiten vor (OA_{ST}) und nach der Adaption (OA_{DA}) dar: $\Delta OA_{DA} = OA_{DA} - OA_{ST}$. Das Vorzeichen von ΔOA_{DA} weist bei $\Delta OA_{DA} < 0$ auf den NT hin. Der Wert von ΔOA_{TD} zeigt einen Verlust der Genauigkeit aufgrund der fehlenden Trainingsdaten in der Zieldomäne an: $\Delta OA_{TD} = OA_{TT} - OA_{DA}$. In der Evaluierung werden zusätzlich die Tests, die zu positivem bzw. negativem Transfer führen, getrennt analysiert. Dabei werden die beiden Maße ΔOA_{DA} und ΔOA_{TD} für diese Tests ausgewertet. Das Superskript „+“ steht beim jeweiligen Maß für das Resultat der Auswertung der Tests, die zu positivem Transfer führen, und das Superskript „-“ für das Resultat der Auswertung der Tests, die zu negativem Transfer führen (z.B. ΔOA_{DA}^+ bzw. ΔOA_{DA}^-). Außerdem werden klassenspezifische Qualitätsmaße Korrektheit, Vollständigkeit und F1-Maß zur Analyse der Genauigkeiten einzelner Klassen verwendet. Weiterhin werden die Fälle mit besonders negativer Entwicklung der Genauigkeit ($\Delta OA_{DA} \ll 0$) auf deren Ursache analysiert. Die Stärken und Schwächen des entwickelten Ansatzes werden darüber hinaus durch ausgewählte Beispiele veranschaulicht und diskutiert.

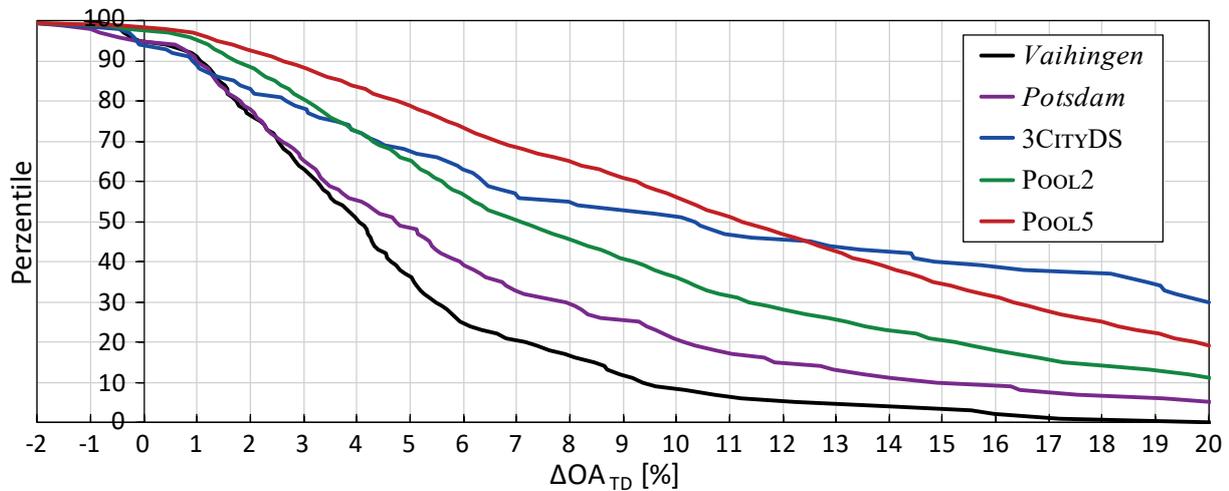
6.3.3 Allgemeine Darstellung der Ergebnisse

Die Ergebnisse der Klassifikation nach der DA sind in Abbildungen 6.16 und 6.17 für die komplette Testreihe für alle Datensätze dargestellt. Die Abbildung 6.16 zeigt mithilfe der Perzentil-Plots für ΔOA_{DA} und ΔOA_{TD} die Änderung der Genauigkeit aufgrund der Anwendung von DA bzw. den Verlust der Genauigkeit nach der DA aufgrund der fehlenden Labels in der Zieldomäne. Abbildung 6.17 zeigt die Qualität der Adaption anhand von klassenspezifischen Qualitätsmaßen. Die zugehörigen Zahlen zur Beurteilung des Verfahrens sind in Tabelle 6.20 präsentiert.

Gemäß ΔOA_{DA} aus der Abbildung 6.16a wird ein positiver Transfer in 42% (135 von 324) aller Tests aus der Testreihe für den *Vaihingen*, in 56% (200 von 361) für *Potsdam*, in 49% (109 von 225) für *3CITYDS*, in 45% (606 von 1369) für *POOL2* und in 46% (1231 von 2704) für den *POOL5* Datensatz erzielt. Damit überwiegt der Anteil von positivem Transfer nur für den *Potsdam* Datensatz. Die präsentierten Werte entsprechen der Differenz aus 100% und dem



(a)



(b)

Abbildung 6.16: Perzentil-Plots mit der DA Performance für die Datensätze *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2*, *POOL5*: (a) ΔOA_{DA} ; (b) ΔOA_{TD} .

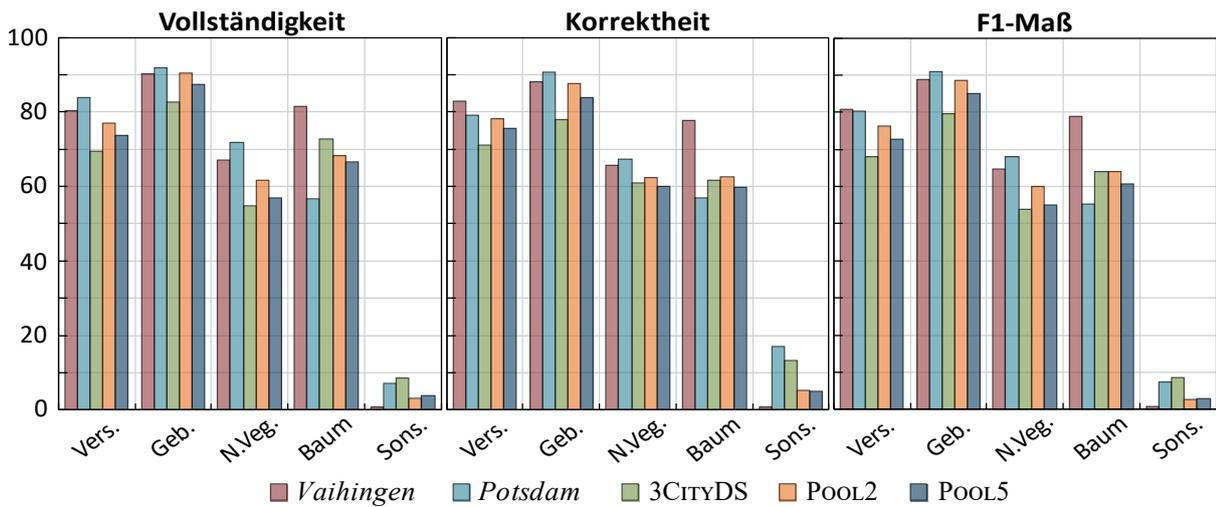


Abbildung 6.17: Mittlere klassenspezifische Qualitätskriterien *Vollständigkeit*, *Korrektheit* und *F1-Maß* für die Datensätze *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2*, *POOL5* (Vers.: *Versiegelte Fläche*, Geb.: *Gebäude*, N.Veg.: *Niedrige Vegetation*, Baum: *Baum*, Sons.: *Sonstiges*).

Tabelle 6.20: Ergebnisse der Evaluierung des DA Ansatzes für die Datensätze *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2*, *POOL5*. Klassenspezifische Qualitätsmaße: *Vollständigkeit* (Comp), *Korrektheit* (Corr), *F1-Maß* (F1). Genauigkeitsmaße: *Gesamtgenauigkeit* (OA), Änderung der Genauigkeit aufgrund der Anwendung der DA (ΔOA_{DA}), Verlust der Genauigkeit aufgrund der fehlenden Trainingsdaten in der Zieldomäne gegenüber der DA (ΔOA_{TD}), auf positiven bzw. negativen Transfer bezogene Genauigkeitsmaße ($\Delta OA_{*}^{+/-}$). Klassen: *Versiegelte Fläche* (Vers.), *Gebäude* (Geb.), *Niedrige Vegetation* (N.Veg.), *Baum* (Baum), *Sonstiges* (Sons.). Statistische Kennwerte: *Median* (Med.), *Mittelwert* (MW), *Standardabweichung* (Std).

		V_{TT}			V_{ST}			V_{DA}								
		Comp	Corr	F1	Comp	Corr	F1	Comp	Corr	F1						
		[%]	[%]	[%]	[%]	[%]	[%]	[%]	[%]	[%]						
Vaihingen	Vers.	86.2	84.7	85.4	83.9	80.5	81.7	80.3	82.9	80.8						
	Geb.	91.4	91.1	91.3	87.9	89.7	88.5	90.2	88.0	88.9						
	N.Veg.	71.9	71.9	71.9	68.4	65.8	66.1	67.0	65.6	64.8						
	Baum	80.3	84.5	82.3	78.0	81.3	78.9	81.5	77.8	78.9	ΔOA_{DA}^{+}	ΔOA_{DA}^{-}	ΔOA_{TD}^{+}	ΔOA_{TD}^{-}	ΔOA_{DA}	ΔOA_{TD}
	Sons	9.1	16.1	9.9	0.7	1.3	0.8	0.8	0.7	0.7						
	OA [%]		84.3			79.9			79.5		0.5	-1.0	2.6	4.9	-0.2	4.0
	Std		3.5			4.5			4.7		1.1	2.5	2.4	4.1	2.4	3.8
Potsdam	Vers.	89.3	82.8	85.9	86.6	77.1	80.5	83.9	79.2	80.4						
	Geb.	93.4	94.0	93.7	89.7	91.6	90.4	91.9	90.6	90.9						
	N.Veg.	79.8	70.1	74.6	75.2	65.9	69.1	71.8	67.3	68.1						
	Baum	53.3	70.5	60.3	49.6	61.3	53.3	56.8	56.9	55.4	ΔOA_{DA}^{+}	ΔOA_{DA}^{-}	ΔOA_{TD}^{+}	ΔOA_{TD}^{-}	ΔOA_{DA}	ΔOA_{TD}
	Sons	20.4	53.9	25.1	5.6	19.4	6.5	7.1	16.9	7.4						
	OA [%]		81.4			76.4			76.3		0.8	-1.1	2.8	6.7	0.2	4.7
	Std		3.2			6.7			7.2		1.3	2.6	4.7	6.9	2.6	6.2
3CITYDS	Vers.	79.5	79.1	79.2	72.3	67.9	67.6	69.5	71.1	68.0						
	Geb.	86.1	86.7	86.4	80.5	79.6	79.2	82.6	78.0	79.7						
	N.Veg.	73.2	74.9	73.5	54.2	61.5	52.1	54.7	60.9	53.9						
	Baum	76.1	81.1	78.4	66.6	68.0	64.2	72.8	61.7	64.1	ΔOA_{DA}^{+}	ΔOA_{DA}^{-}	ΔOA_{TD}^{+}	ΔOA_{TD}^{-}	ΔOA_{DA}	ΔOA_{TD}
	Sons	24.6	45.3	28.0	7.7	14.6	8.2	8.5	13.4	8.6						
	OA [%]		81.2			71.3			71.3		1.3	-2.5	5.7	16.5	-0.1	10.4
	Std		3.4			11.9			11.7		3.1	4.4	12.0	11.1	5.0	11.9
Pool2	Vers.	87.8	83.7	85.7	83.0	75.6	78.0	77.1	78.2	76.3						
	Geb.	92.5	92.6	92.5	88.0	88.8	88.0	90.4	87.7	88.6						
	N.Veg.	76.0	71.0	73.3	67.1	62.6	63.4	61.6	62.4	60.1						
	Baum	66.5	77.3	71.0	57.7	68.4	60.9	68.2	62.6	63.9	ΔOA_{DA}^{+}	ΔOA_{DA}^{-}	ΔOA_{TD}^{+}	ΔOA_{TD}^{-}	ΔOA_{DA}	ΔOA_{TD}
	Sons	14.9	35.5	17.7	2.6	6.4	2.5	3.1	5.2	2.7						
	OA [%]		81.9			75.9			75.0		1.2	-2.2	4.7	10.2	-0.3	7.1
	Std		3.5			7.5			8.4		2.3	4.1	5.3	8.0	4.5	7.6
Pool5	Vers.	85.4	82.4	83.8	79.5	72.0	73.6	73.6	75.6	72.8						
	Geb.	90.6	90.9	90.8	84.8	85.4	84.4	87.3	83.9	85.0						
	N.Veg.	75.2	72.1	73.4	59.8	60.6	56.5	57.0	60.1	55.1						
	Baum	69.2	78.4	73.2	57.4	65.7	58.2	66.7	59.9	60.6	ΔOA_{DA}^{+}	ΔOA_{DA}^{-}	ΔOA_{TD}^{+}	ΔOA_{TD}^{-}	ΔOA_{DA}	ΔOA_{TD}
	Sons	17.7	38.3	20.7	3.1	6.1	2.8	3.7	5.1	3.0						
	OA [%]		81.8			71.4			70.5		1.6	-2.7	7.9	14.5	-0.3	11.2
	Std		3.5			8.8			9.1		2.9	4.3	7.9	8.6	5.0	8.7

Schnittpunkt der jeweiligen Kurve mit der vertikalen Achse im Perzentil-Plot. In ähnlicher Weise liest man aus der Abbildung ab, dass für ca. 95% der Tests aus *Vaihingen* und *Potsdam* und für 85% der Tests aus 3CITYDS, POOL2 und POOL5 der Verlust weniger als 5% in *OA* mit dem entwickelten DA Ansatz beträgt. Eine Verbesserung von mindestens 2% in *OA* wird nach der DA in 5%, 9%, 20%, 15% bzw. 21% der Tests aus den Datensätzen *Vaihingen*, *Potsdam*, 3CITYDS, POOL2 bzw. POOL5 erreicht. Die Abbildung 6.16b zeigt mit ΔOA_{TD} dagegen den Verlust in der Gesamtgenauigkeit nach der DA aufgrund der fehlenden Labels in der Zieldomäne. Bei 50% der Tests aus dem jeweiligen Datensatz, was ungefähr dem Anteil an positivem Transfer entspricht, geht weniger als < 4.0% in *OA* für *Vaihingen*, < 4.7% in *OA* für *Potsdam*, < 10.4% in *OA* für 3CITYDS, < 7.1% in *OA* für POOL2 und < 11.2% in *OA* für POOL5 verloren. Den kleinsten Verlust der Genauigkeit aufgrund der fehlenden Trainingsdaten in der Zieldomäne zeigen die Datensätze *Vaihingen* und *Potsdam*. Für eine kleine Anzahl der Tests übersteigt die Gesamtgenauigkeit nach der DA das Ergebnis der Klassifikation mit dem Basisklassifikator, der direkt an der Zieldomäne unter Verwendung der gelabelten Daten angelern wurde ($\Delta OA_{TD} < 0\%$). Die Verbesserung gegenüber OA_{TT} nach der DA wurde in fast allen Tests erreicht, in denen Quell- und Zieldomäne identisch waren; die Ausnahme bildet nur die Kachel 05 vom Testgebiet *Vaihingen* und die Kachel 231 vom Testgebiet *Hannover*. Dabei liegt die Verbesserung bei ca. 0.4% für den *Vaihingen*, bei 1.0% für den *Potsdam*, bei 0.6% für den 3CITYDS und bei 0.7% sowohl für den POOL2 als auch für den POOL5 Datensatz. Damit ist es der DA unter Verwendung der identischen Domänen gelungen, die Genauigkeit der Klassifikation auf der Zieldomäne gegenüber dem LR-Klassifikator zu verbessern. Ein Beispiel für solche Verbesserung ist in Abbildung 6.18 präsentiert.

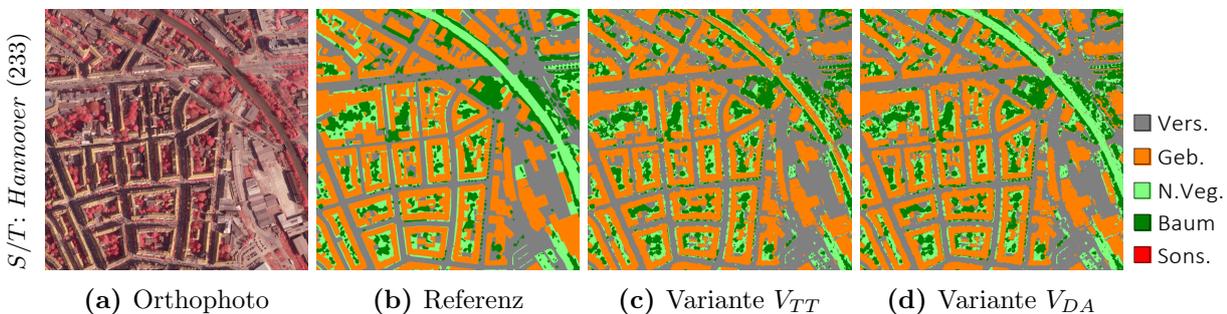


Abbildung 6.18: Beispiel für die Verbesserung der Qualität nach der DA gegenüber der Variante TT , in dem die Quell- und Zieldomäne gleich sind (Kachel 233 aus dem Testgebiet *Hannover*). In der Variante TT wird der Klassifikator direkt an der Zieldomäne unter Verwendung der gelabelten Daten angelern. Somit entspricht Ergebnis in dieser Variante dem optimalen Ergebnis mit der LR als Basisklassifikator. Exakte Werte zur Beurteilung der Qualität der DA sind in Tabelle 6.21 zusammengefasst.

Tabelle 6.21: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.18.

	$F1$ [%]					OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
	Vers.	Geb.	N.Veg.	Baum	Sons.			
V_{TT}	82.0	86.1	49.7	75.9	0.0	78.9		
V_{ST}	82.0	86.1	49.7	75.9	0.0	78.9	2.6	-2.6
V_{DA}	83.2	88.7	62.0	76.0	0.0	81.5		

Die Abbildung 6.17 veranschaulicht klassenspezifische Qualitätsmaße Vollständigkeit, Korrektheit und $F1$ -Maß nach der DA. Am besten sind die Ergebnisse für die Klassen *Versiegelte Fläche*

und *Gebäude*. Für die Klasse *Gebäude* liegen die Ergebnisse für fast alle Qualitätsmaße über 80%; die Ausnahme ist die Korrektheit mit 78.0% und als Folge das F1-Maß (harmonisches Mittel aus Korrektheit und Vollständigkeit) mit 79.7% für den 3CITYDS Datensatz. Die Klassen *Niedrige Vegetation* und *Baum* liegen bei den drei Qualitätsmaßen über 55% für alle Datensätze bzw. kommen diesem Wert nahe (Ausnahmen: 54.7% und 53.9% für Vollständigkeit bzw. F1-Maß für den 3CITYDS Datensatz). Am schlechtesten sind die Werte für die relativ seltene Klasse *Sonstiges*. Die Qualitätsmaße dieser Klasse erreichen für *Vaihingen* Werte von nur etwa 0.7%. Die besten Ergebnisse erreicht die Klasse *Sonstiges* bei dem *Potsdam* bzw. dem 3CITYDS Datensatz mit den zugehörigen Werten für das F1-Maß von 7.4% bzw. 8.6%.

Die erzielten klassenspezifischen Qualitätsmaße (Vollständigkeit, Korrektheit und F1-Maß) sowie die Gesamtgenauigkeiten OA für die Varianten V_{TT} , V_{ST} , V_{DA} und die daraus abgeleitete Genauigkeitsmaße ΔOA_{DA} bzw. ΔOA_{TD} sind in der Tabelle 6.20 zu finden. Bei dem *Vaihingen* Datensatz wird z.B. eine mittlere Gesamtgenauigkeit von etwa 84.0% mit der LR als Basisklassifikator erreicht, wenn gelabelte Daten in der Zieldomäne vorliegen würden (V_{TT}). Wendet man einen Klassifikator, der an der Quelldomäne antrainiert wurde, direkt auf die Zieldomäne an, erzielt man eine mittlere Gesamtgenauigkeit von 79.9% (V_{ST}). Die mittlere Gesamtgenauigkeit nach der Adaption liegt demgegenüber bei 79.2% (V_{DA}). Dies entspricht einem Verlust von etwa 0.7% (ΔOA_{DA}) gegenüber der Variante V_{ST} bzw. ist im Mittel um ca. 4.7% (ΔOA_{TD}) schlechter im Vergleich zu dem Fall, bei dem die Labels in der Zieldomäne zur Verfügung stehen. Im Allgemeinen fallen die Werte ΔOA_{DA} bzw. ΔOA_{TD} für gemischte Datensätze 3CITYDS, POOL2 und POOL5, die mehrere Testgebiete beinhalten, etwas schlechter aus. Vor allem liegt der Verlust der Genauigkeit ΔOA_{TD} aufgrund der fehlenden Trainingsdaten in der Zieldomäne um mindestens 2.4% über den entsprechenden Werten für den *Vaihingen* und *Potsdam* Datensatz. Dies deutet auf größere Schwierigkeiten bei der Adaption mit dem entwickelten Ansatz zwischen den unterschiedlichen Gebieten hin. Das ist nachvollziehbar, denn die Unterschiede in den Charakteristika einzelner Testgebiete führen zu einer steigenden Diskrepanz zwischen den Domänen.

Zur tieferen Analyse der Adaption zwischen unterschiedlichen Testgebieten werden die Ergebnisse der Datensätze 3CITYDS, POOL2 und POOL5 betrachtet. Dabei werden nur die Tests berücksichtigt, in denen die DA zwischen den Kacheln aus unterschiedlichen Testgebieten stattfindet. Die zugehörigen durchschnittlichen Werte ΔOA_{DA} liegen bei -0.8% (Med. -0.3%), -2.0% (Med. -1.3%) bzw. -1.3% (Med. -0.7%) für den 3CITYDS, POOL2 bzw. POOL5 Datensatz. Nichtsdestotrotz wird ein positiver Transfer in 67 aus 150 (44.7%) Tests für den 3CITYDS Datensatz, in 271 aus 684 (39.6%) Tests für den POOL2 Datensatz und in 854 aus 1944 (43.9%) Tests für den POOL5 Datensatz erreicht. Damit ist mit dem entwickelten Ansatz ein positiver Transfer auch zwischen verschiedenen Gebieten möglich, deren Bilddaten sich in Bezug auf die Aufnahmesensorik, Lichtverhältnisse und saisonale Effekte unterscheiden. Eine weitere interessante Untersuchung in Bezug auf Skaleninvarianz stellt die Adaption zwischen den Testgebieten mit unterschiedlicher GSD. Dafür werden ausschließlich die Tests aus dem POOL5 Datensatz analysiert, in denen die Bildkacheln der Quell- und Zieldomäne den Testgebieten mit unterschiedlicher GSD gehören. Der positive Transfer wird dabei in 516 aus 1110 (46.5%) Tests erreicht. Damit ist der positive Transfer auch zwischen verschiedenen Gebieten möglich, die zudem in der Auflösung

der Daten (Bodenpixelgröße) unterschiedlich sind. Der zugehörige Mittelwert von ΔOA_{DA} für die 1110 Tests liegt bei -0.9% (Med. -0.5%).

Die Werte von ΔOA_{DA} im Bereich von -0.4% (*Potsdam*) bis -1.2% (POOL2) zeigen einen NT über die Testreihen hinweg, wenn man die Mittelwerte betrachtet (siehe Tabelle 6.20). Die Werte des Medians sind im Allgemeinen für alle Datensätze besser. Damit wird anhand vom Median beim *Potsdam* Datensatz ein leicht positiver Transfer von 0.2% über die Testreihe erreicht. Der positive Wert des Medians weist darauf hin, dass in mehr als 50% der Tests ein positiver Transfer erreicht wird. Da der Mittelwert (im Unterschied zu Median) durch einzelne stark abweichende Genauigkeitsmaße beeinflusst wird, deutet ein deutlich niedrigerer Mittelwert von ΔOA_{DA} im Vergleich zu Median in dem jeweiligen Datensatz auf einige Ausreißer mit sehr starkem NT hin. Betrachtet man die Tests mit positivem Transfer separat, stellt man fest, dass die durchschnittliche Verbesserung ΔOA_{DA}^+ von 1.0% bei dem *Vaihingen* bis zu 2.6% bei dem 3CITYDS und POOL5 erreicht wird. Der durchschnittliche Genauigkeitsverlust ΔOA_{TD}^+ gegenüber einem erneut anhand der gelabelten Trainingsdaten angelesenen Klassifikator liegt im Bereich von 10.5% bei dem 3CITYDS bis 2.9% bei dem *Vaihingen* Datensatz. Dabei sind die Werte des Medians meist wesentlich besser, so liegt der Median von ΔOA_{TD}^+ für den 3CITYDS bei 5.7% . Damit deutet dieser Unterschied auf einzelne Ausreißer innerhalb der Tests mit einem positiven Transfer hin. Einzelne Ausreißer sowie Ursachen für den NT werden im nächsten Abschnitt untersucht.

6.3.4 Datensatzspezifische Ergebnisse

Nachfolgend wird auf die Testergebnisse der DA in einzelnen Datensätzen im Detail eingegangen. Der Schwerpunkt liegt auf den schwierigen Fällen, um die Grenzen des Verfahrens zu analysieren und das Verhalten der DA besser zu verstehen.

Vaihingen. Bei der Analyse der klassenspezifischen Qualitätsmaße für den *Vaihingen* Datensatz (siehe Tabelle 6.20) fallen relativ schlechte Werte für die Klasse *Sonstiges* auf. Das $F1$ -Maß fällt von 9.9% in der Variante V_{TT} auf 0.8% in V_{ST} und verringert sich geringfügig um 0.1% auf 0.7% in der Variante V_{DA} nach der DA, während es für andere Datensätze ein Zuwachs der Qualität mit dem $F1$ -Maß nach der DA festgestellt werden kann. Ganz allgemein betrachtet resultieren solche niedrigen Durchschnittswerte des $F1$ -Maßes daraus, dass die Klasse *Sonstiges* in nur 4 aus 18 Bildkacheln vorkommt. Folglich wird für die Klasse *Sonstiges* ein Wert von 0% in den meisten Tests erreicht. Weiterhin wird die Annahme der DA nach der gleichen Klassenstruktur in der Quell- und Zieldomäne in nur 16 aus 324 Tests eingehalten, in denen also ein $F1$ -Wert größer als Null nach der DA erreicht werden kann. Betrachtet man nur diese 16 Tests, so erhält man mittlere $F1$ -Werte für die Klasse *Sonstiges* von 44.5% , 15.8% , 14.4% für die Varianten V_{TT} , V_{ST} bzw. V_{DA} . In Bezug auf die DA ist die Verschlechterung des $F1$ -Maßes der Klasse *Sonstiges* in der Variante V_{DA} gegenüber der V_{ST} auf eine mäßige Ähnlichkeit zwischen den bedingten Verteilungen dieser Klasse in Quell- und Zieldomäne zurückzuführen. Bedingt durch die Definition weist die Klasse *Sonstiges* in Abhängigkeit von der Beschaffenheit des jeweiligen referenzierten Objektes im Bild Merkmalsausprägungen auf, die sich in Quell- und Zieldomäne stark unterscheiden können (siehe Abbildung 6.19). Damit wird die Annahme nach ähnlichen

Domänen verletzt, was folglich zu Fehlern im Adaptionsprozess und einem NT führen kann. Darüber hinaus ist diese Klasse sehr heterogen und weist oft die Merkmalsausprägungen auf, die auch für andere Klassen typisch sind. So beinhaltet sie in der Kachel mit der Nummer 20 aus Abbildung 6.19 einen Sportplatz, dessen Merkmalsausprägungen jenen der Klasse *Niedrige Vegetation* oder *Versiegelte Fläche* mit kleinen n_{DOM} und relativ kleinen n_{DVI} -Werten ähneln. In der Kachel 26 wurde hingegen Wasser und eine kleine Lagerfläche der Klasse *Sonstiges* zugewiesen. Die Merkmale sind in diesem Fall über den gesamten Merkmalsraum verteilt, wobei sich eine Anhäufung im Koordinatenursprung bildet, die wegen der niedrigen n_{DOM} - und n_{DVI} -Werte eher für die Klasse *Versiegelte Fläche* typisch ist. Solche unterrepräsentierte und stark streuende Merkmalsausprägungen in der Zieldomäne können während der DA zu einer Zuweisung zur falschen Klasse führen, da die Semi-Labels auf Basis einer lokalen Analyse (von K -NN und aus dem aktuellen Zustand des Klassifikators) zugewiesen werden. Aus diesen Gründen fällt der $F1$ -Maß der Klasse *Sonstiges* beim Test mit der Kachel 20 als Quell- und der Kachel 26 als Zieldatei nach der DA von 70.1% in der Variante V_{ST} auf 60.1% in der Variante V_{DA} . Dies entspricht einer Reduktion des $F1$ -Wertes um 17.3% gegenüber dem Wert von 77.4% in der Variante V_{TT} . Die Adaption schlägt in diesem Fall fehl und führt zu NT ($OA_{ST} = 82.1\%$, $OA_{DA} = 78.3\%$, $\Delta OA_{DA} = -3.8\%$).

Bei der Analyse der Fälle, die zu einem NT führen, fallen jene mit Kachel 17 als Quelldomäne besonders auf. Es gibt insgesamt 18 Tests mit einer solchen Konstellation in der gesamten Testreihe, die bei dem *Vaihingen* Datensatz aus 324 Tests besteht. Diese Tests weisen den größten Verlust der Genauigkeit nach der DA auf. Ein NT wird in 12 aus 18 Tests erreicht. Im Mittel über 18 Tests reduziert sich das Qualitätsmaß ΔOA_{DA} um -3.8% pro Test. Der Mittelwert von ΔOA_{DA}^+ liegt bei 2.1%, während der Mittelwert von ΔOA_{DA}^- bei -6.7% liegt. Dabei geht die Qualität der Adaption im Mittel bei den Klassen *Niedrige Vegetation* und *Baum* am stärksten verloren. Der Verlust im $F1$ -Maß in der Variante V_{DA} gegenüber der Variante V_{ST} liegt bei -4.8% für die Klasse *Niedrige Vegetation* bzw. bei -4.1% für *Baum*. Für die Klasse *Gebäude* konnte es hingegen um 2.3% verbessert werden. Bei einer näheren Untersuchung wurde festgestellt, dass für einen Bereich mit Weingarten als Referenzklasse *Niedrige Vegetation* festgelegt wurde, wobei die Höhe basierend auf Daten des n_{DOM} eher jenen der Klasse *Baum* entspricht (siehe Abbildung 6.20). Dies führt dazu, dass im Merkmalsraum ein Überlappungsbereich zwischen den Verteilungen der Klasse *Niedrige Vegetation* und *Baum* entsteht. Durch diese Überlappung können die Verteilungen der beiden Klassen sogar in der Variante V_{SS} , in der der Klassifikator an den Daten derselben Domäne trainiert wurde, nicht sicher von einander getrennt werden. Dabei liegt der ermittelte Wert der Vollständigkeit für *Baum* bei nur 59.3% ($F1$ -Maß: 66.3%). Die Qualität der Klassifikation der Klasse *Gebäude*, deren Merkmalsausprägungen deutlich unterschiedliche Charakteristika aufweisen, ist in der Variante V_{SS} kaum betroffen; der $F1$ -Maß beträgt hier 94.3%. Dennoch scheint es so zu sein, dass für die Anwendung der DA die Verteilung der Merkmale in dieser Kachel zu unterschiedlich zu den Verteilungen aus anderen Kacheln ist, also die Ähnlichkeitsbedingung ist nicht erfüllt, wodurch die Adaption in den meisten Fällen zu NT mit einem großen Verlust der Genauigkeit führt. Dabei ist 17 die einzige Kachel mit Weingarten in dem Datensatz $\mathfrak{D}_{\mathfrak{U}_3}^{V_{ai}}$. Ein Beispiel für die Adaption mit der Bildkachel 17 als Quelle wird in Abbildung 6.21 präsentiert. Als Zieldomäne fungiert dabei die Kachel 11. Durch zusätzliche

Stichproben aus dem Weingarten in der Kachel 17 wird ein Teil des Merkmalsraums, der eher typisch für die Klasse *Baum* ist, beim Training des initialen Klassifikators der Klasse *Niedrige Vegetation* zugewiesen. Dadurch steigt die Vollständigkeit für *Niedrige Vegetation* in der Variante V_{ST} gegenüber V_{TT} um 15.3% auf 76.7%, zugleich fällt aber die Korrektheit um 16.0% auf 49.7% (siehe Abbildung 6.21). Aufgrund der Nichteinhaltung der Ähnlichkeitsbedingung schlägt weiterhin die Adaption mit $\Delta OA_{DA} = -6.0\%$ fehl. Wäre eine fehlerfreie Erkennung vom NT in diesem Fall möglich, wodurch die 12 Tests mit der Kachel 17 in der Quelldomäne erkannt und ausgeschlossen wären, würde dies zu einer mittleren Verbesserung des Qualitätsmaßes ΔOA_{DA} von -0.7% auf -0.4% (im Median auf -0.1%) über die gesamte Testreihe führen.

Weiterhin fallen bei der Analyse der DA-Ergebnisse jene mit Kachel 35 als Zieldomäne positiv auf. Es wird für 16 aus 18 Tests mit dieser Kachel in der Zieldomäne ein positiver Transfer erreicht, deren Qualitätsmaß ΔOA_{DA} im Mittel über alle 18 Tests einen Wert von 2.1% pro Test erreicht. Der Mittelwert von ΔOA_{DA}^+ liegt bei 2.3%, während der Mittelwert von ΔOA_{DA}^- bei -0.1% liegt. In den 18 Tests verbessert sich die Qualität der Adaption für die Klasse *Gebäude* in der Variante V_{DA} gegenüber V_{ST} am meisten: im Mittel um 5.1% ($F1$ -Differenz). Die Klasse *Niedrige Vegetation* verliert mit -0.5% ($F1$ -Differenz) als einzige Klasse an der Qualität nach der DA gegenüber der Qualität vor der DA. Die Abbildung 6.22 zeigt die Kachel 35 aus dem *Vaihingen* Datensatz. Sie beinhaltet mit Ausnahme der Klasse *Sonstiges* einen relativ gleichen Anteil der Gesamtstichproben pro Klasse: jeweils 26% für die Klassen *Versiegelte Fläche* und *Gebäude*, 25% für *Niedrige Vegetation*, 23% für *Baum* und 0% für *Sonstiges*. Außerdem weist sie eine gute Variation ohne starke Überlappungen in den Merkmalsausprägungen der einzelnen Klassen auf (siehe Abbildung 6.22). Die beiden Faktoren scheinen die Kachel 35 zu der optimalen Zieldomäne innerhalb vom *Vaihingen* Datensatz zu machen. Ein exemplarisches Ergebnis für die DA mit der Kachel 05 als Quell- und der Kachel 35 als Zieldomäne ist in Abbildung 6.23 vorgestellt. In diesem Fall wurde ein positiver Transfer mit ΔOA_{DA} von 6.6% erreicht. Obwohl der Anteil der beiden Vegetationsklassen in dem Quellbild sehr gering ist, hat sich die Qualität der Erkennung der Klasse *Niedrige Vegetation* ($F1$ -Maß) nach der DA nur geringfügig um 0.1% verschlechtert; zugleich stieg die Qualität der Erkennung der Klasse *Baum* fast um 12%.

Potsdam. Die Genauigkeitswerte der DA auf dem *Potsdam* Datensatz sind in vielen Punkten mit denen von *Vaihingen* vergleichbar. Basierend auf dem Median von ΔOA_{DA} wird auf diesem Datensatz ein leicht positiver Transfer von 0.2% erreicht. Das heißt, dass in mehr als 50% der Tests ein positiver Transfer erreicht wird. Es ist jedoch zu bemerken, dass die Parametereinstellungen auf den Bilddaten des Testgebietes *Potsdam* (wenn auch unter Verwendung eines unterschiedlichen Satzes von Bildkacheln) stattgefunden hat. Damit ist eine gewisse Überanpassung an *Potsdam* Datensatz nicht auszuschließen.

Die Auswertung der klassenspezifischen Qualitätsmaße aus Tabelle 6.20 zeigt im Vergleich zu den anderen Datensätzen fast überall die besten Erkennungsraten sowie vor als auch nach der DA. Die Klasse *Baum* stellt jedoch eine Ausnahme dar. Ein stark reduzierter Laubwerk der Bäume ist charakteristisch für Bilddaten des Testgebietes *Potsdam*. Dadurch erfassten die Sensoren bei der Aufnahme teilweise nicht die Information des Objektes *Baum*, sondern der darunter liegenden Objekte (meist *Versiegelte Fläche* oder *Niedrige Vegetation*). In der Referenz dagegen

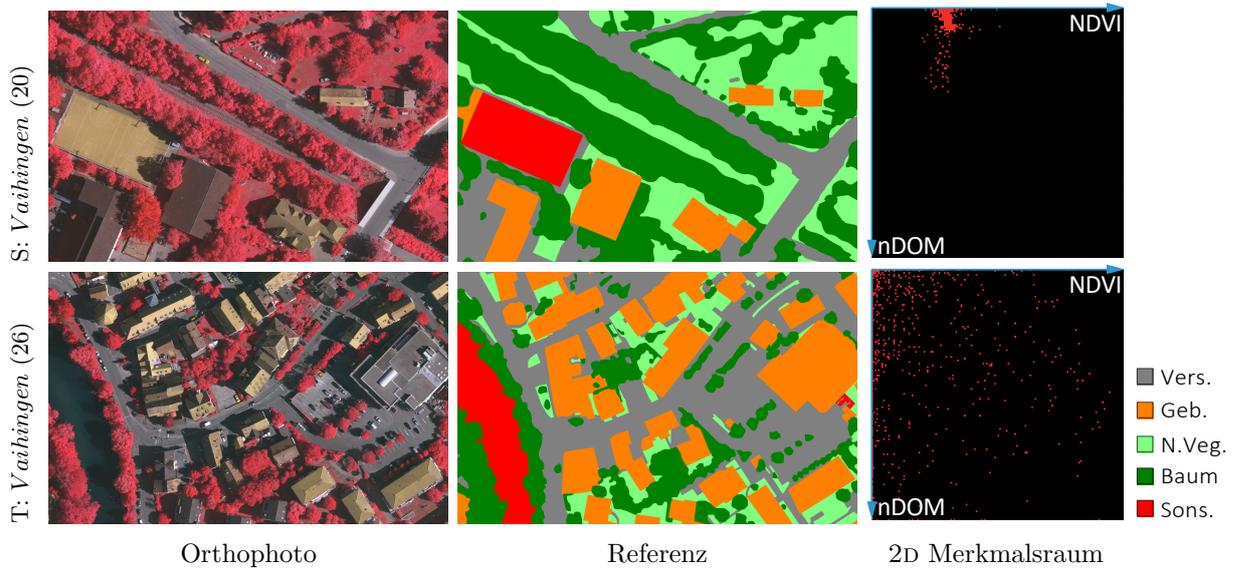


Abbildung 6.19: Beispiel zur Veranschaulichung der Unterschiede in den bedingten Verteilungen der Klasse *Sonstiges* zwischen zwei Bildkacheln (jeweils ein Ausschnitt): Orthophoto, Referenzbild und Merkmalsraum (zur Visualisierung auf zwei Merkmale reduziert). Der Klasse *Sonstiges* wird in der Kachel 20 ein Sportplatz als Objekt zugewiesen. Die Merkmalsausprägungen bilden hier einen zusammenhängenden Cluster. In der Kachel 26 wird Wasser und eine kleine Lagerfläche als *Sonstiges* festgelegt. Die Merkmale streuen in diesem Fall über den gesamten Merkmalsraum. Die Tabelle unten zeigt die im Verlauf der DA erzielten Genauigkeiten. Exakte Werte zur Beurteilung der Qualität der DA für das Beispiel sind in Tabelle 6.22 zusammengefasst.

Tabelle 6.22: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.19.

	Vers.	Geb.	F1 [%]			OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
			N.Veg.	Baum	Sons.			
V_{TT}	84.3	91.1	67.1	90.9	77.4	85.5		
V_{ST}	80.7	88.6	58.4	90.2	70.1	82.1	-3.8	7.2
V_{DA}	72.6	89.6	59.9	89.9	60.1	78.3		

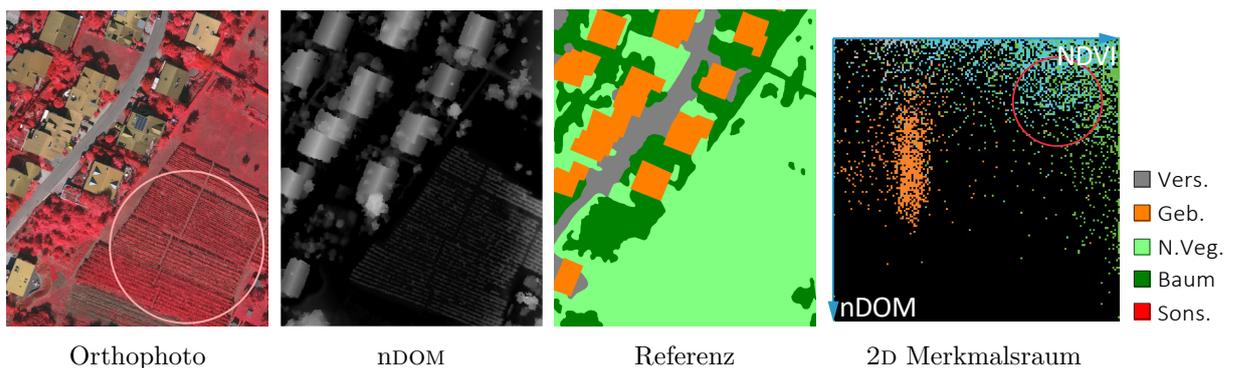


Abbildung 6.20: Ausschnitt einer Region aus der TOP, nDOM und der Referenz sowie der zugehörige Merkmalsraum (zur Visualisierung reduziert auf zwei Merkmale nDOM und NDVI) für die Kachel 17 des *Vaihingen* Datensatzes. Der rote Kreis markiert im Orthophoto den Problembereich mit dem Weingarten. In diesem Bereich entsprechen die nDOM-Werte den Werten der Klasse *Baum*, wohingegen die Referenz die Klasse *Niedrige Vegetation* enthält. Der rote Kreis im Merkmalsraum markiert die dadurch entstandene Überlappung der Verteilungen der Klassen *Niedrige Vegetation* und *Baum*.

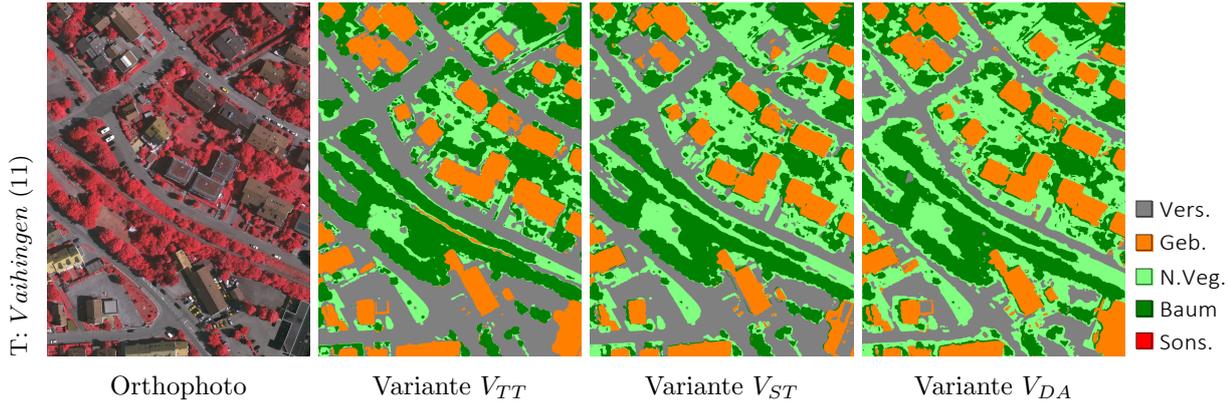


Abbildung 6.21: Exemplarisches Ergebnis der DA für den *Vaihingen* Datensatz mit der Kachel 17 (Abbildung 6.20) als Quell- und der Kachel 11 als Zieldomäne. Exakte Werte zur Beurteilung der Qualität der Adaption für das Beispiel sind in Tabelle 6.23 zusammengefasst.

Tabelle 6.23: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.21. Der große Unterschied in den Verteilungen der Merkmalsausprägungen zwischen der Quell- und Zieldomäne führt zum NT mit ΔOA_{DA} von -6.0% .

	$F1$ [%]					OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
	Vers.	Geb.	N.Veg.	Baum	Sons.			
V_{TT}	88.3	91.2	63.5	87.2	0.0	84.5		
V_{ST}	83.6	84.8	60.3	77.6	0.0	77.2	-6.0	13.3
V_{DA}	69.5	90.3	53.0	76.2	0.0	71.2		

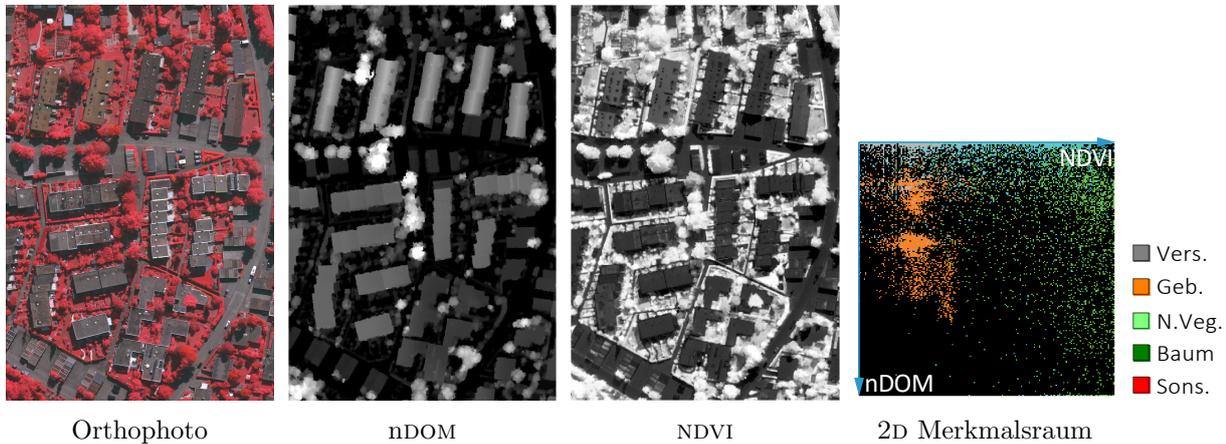


Abbildung 6.22: Orthophoto, nDOM und Referenzdatei sowie der zugehörige Merkmalsraum (zur Visualisierung reduziert auf zwei Merkmale nDOM und NDVI) für die Kachel 35 des *Vaihingen* Datensatzes. Die Kachel 35 weist einen relativ gleichen Anteil der Stichproben pro Klasse und eine gute Variation in den Merkmalsausprägungen der einzelnen Klassen ohne starke Überschneidungen deren Verteilungen im Merkmalsraum auf. Das scheint sie zu der optimalen Zieldomäne zu machen, sodass es für 16 aus 18 DA Tests mit dieser Kachel in der Zieldomäne ein positiver Transfer erreicht wird.

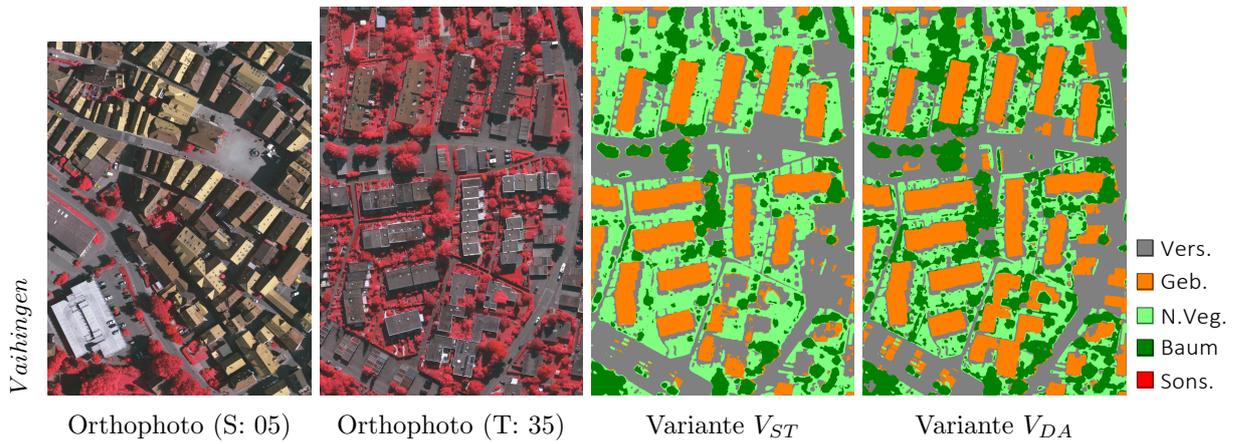


Abbildung 6.23: Exemplarisches Ergebnis der DA für den *Vaihingen* Datensatz mit der Kachel 05 als Quell- und der Kachel 35 (Abbildung 6.22) als Zieldomäne. Exakte Werte zur Beurteilung der Qualität der Adaption für das Beispiel sind in Tabelle 6.24 zusammengefasst.

Tabelle 6.24: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.23. Dabei wird nach der DA ein positiver Transfer mit ΔOA_{DA} von 6.6% erreicht.

	$F1$ [%]					OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
	Vers.	Geb.	N.Veg.	Baum	Sons.			
V_{TT}	84.3	91.9	70.2	76.9	0.0	81.1		
V_{ST}	75.3	77.2	67.5	63.3	0.0	71.2	6.6	3.3
V_{DA}	80.4	87.9	67.4	75.0	0.0	77.6		

wurden Baumkronen durch ihr Umrisspolygon erfasst. Dies resultiert in der Verfälschung der spektralen sowie 3D-basierten Merkmale der Klasse *Baum* über das gesamte Testgebiet. Ein repräsentatives Beispiel zur Veranschaulichung des Problems wird in Abbildung 6.24 vorgestellt. Durch solche verfälschte Merkmalsausprägungen entstehen im Merkmalsraum Überlappungen der Verteilung von *Baum* mit den anderen Klassenverteilungen. Eine Überlappung mit der Verteilung der Klasse *Niedrige Vegetation* entsteht z.B., falls der IR-Wert des Baumes richtig erfasst wurde (NDVI-Wert relativ groß) und der nDOM-Wert jenen des Bodens entspricht (nDOM-Wert klein). Anderes Beispiel ist die Überlappung mit der Verteilung der Klasse *Gebäude*, welche entsteht, falls der IR-Kanal an der Stelle kleine Werte aufweist (NDVI-Wert klein) und der nDOM-Wert jenen der Gebäude entspricht (nDOM-Wert relativ groß). Auch ist eine Überlappung mit der Klasse *Versiegelte Fläche* möglich, falls sowohl IR als auch nDOM relativ kleine Werte aufweisen. Während der DA kann dies dazu führen, dass Stichproben im Überlappungsbereich ein falsches Semi-Label zugewiesen wird. Dieser Sachverhalt ist in Abbildung 6.25 unter Variante V_{ST} veranschaulicht (vgl. markierte Bereiche in Abbildung 6.24). Durch direkte Anwendung des initialen Klassifikators in der Variante V_{ST} , der an der Quelldomäne antrainiert wurde, werden der Klasse *Baum* falsche Labels von allen restlichen Klassen zugewiesen. Dies spiegelt sich unter anderem in dem Abfall des $F1$ -Maßes in der Variante V_{ST} gegenüber der Variante V_{TT} wieder (siehe Tabelle 6.25). Anschließende Anwendung der DA kann das Problem nur teilweise lösen (vgl. Varianten V_{ST} und V_{DA} aus Abbildung 6.25), wobei das Gesamtergebnis der Adaption für die Kachel 03_13 mit $\Delta OA_{DA} = -0.3\%$ zu einem NT führt. Damit stellen die abweichenden oder gar untypischen Werte der Merkmalsausprägungen der Klassen eine Herausforderung für den entwickelten Ansatz zur DA dar.

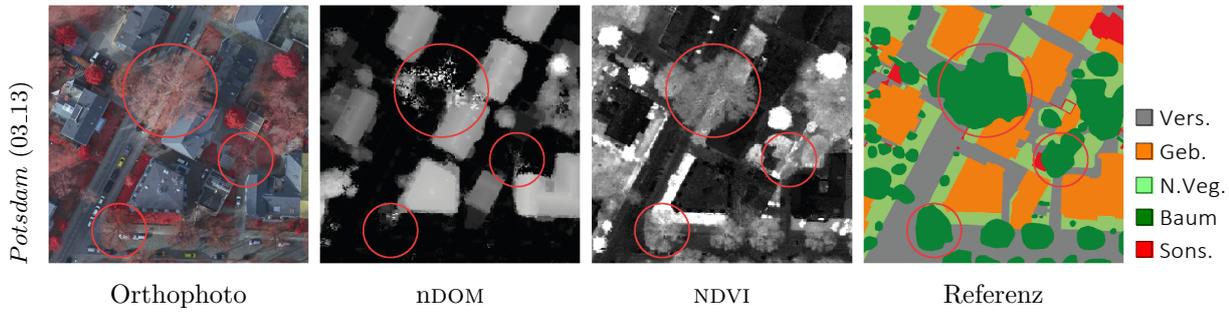


Abbildung 6.24: Ausschnitt aus dem Orthophoto, der nDOM-, NDVI- und Referenzdateien der Kachel 03_13 aus dem *Potsdam* Datensatz zur Veranschaulichung des Problems mit den relativ niedrigen Genauigkeitswerten der Klasse *Baum* (vgl. Tabelle 6.20). Aufgrund der fehlenden Belaubung in den markierten Bereichen werden spektrale sowie 3D Merkmale auf Basis des nDOM verfälscht: Die Sensoren erfassten bei der Aufnahme teilweise nicht die Information des Objektes *Baum*, sondern der darunter liegenden Objekte. In den Referenzdaten dagegen wurden Baumkronen durch ihr Umrisspolygon erfasst.

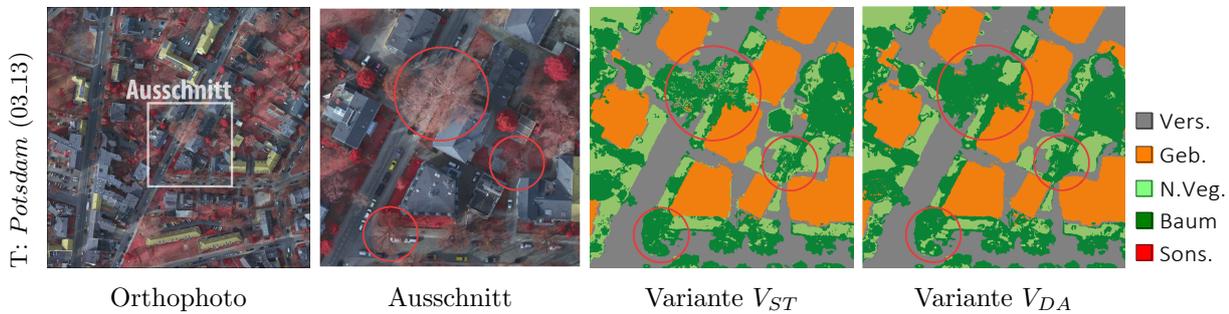


Abbildung 6.25: Exemplarisches Ergebnis der DA für den *Potsdam* Datensatz mit der Kachel 05_11 als Quell- und der Kachel 03_13 (vgl. Abbildung 6.24) als Zieldomäne. Exakte Werte zur Beurteilung der Qualität der Adaption für das Beispiel sind in Tabelle 6.25 zusammengefasst.

Tabelle 6.25: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.25. Dabei wird nach der DA ein NT mit ΔO_{DA} von -0.3% erreicht.

	$F1$ [%]					OA [%]	ΔO_{DA} [%]	ΔO_{TD} [%]
	Vers.	Geb.	N.Veg.	Baum	Sons.			
V_{TT}	84.8	93.3	72.2	71.7	0.9	79.9		
V_{ST}	84.4	92.9	69.0	69.1	0.8	78.5	-0.3	1.7
V_{DA}	84.3	93.0	67.7	68.9	0.1	78.2		

In Bezug auf NT fällt die Kachel 07_07 in der Rolle der Quelldomäne auf (siehe Abbildung 6.26). Es gibt insgesamt 19 Tests mit dieser Kachel als Quelldomäne in der Testreihe. In diesen Tests führt die DA zum größten Genauigkeitsverlust durch NT. Ein positiver Transfer wird in nur 4 von 19 Tests erreicht, in einem davon sind Quell- und Zieldomäne identisch. Es verringert sich dabei im Durchschnitt über alle 19 Tests das Qualitätsmaß ΔO_{DA} um -4.3% . Der Mittelwert von ΔO_{DA}^+ liegt bei 0.9% , während der Mittelwert von ΔO_{DA}^- bei -5.7% liegt. Dabei geht die Qualität der Adaption im Mittel bei den Klassen *Versiegelte Fläche* am stärksten verloren: Der Verlust im $F1$ -Maß in der Variante V_{DA} gegenüber der Variante V_{ST} liegt bei -7.9% . Zugleich konnte für die Klassen *Gebäude* und *Sonstiges* der $F1$ -Wert um 1.0 bzw. 7.9% verbessert werden. Eine nähere Untersuchung der Verteilungen der Merkmalsausprägungen aus Abbildung 6.27 offenbart eine starke Überlappung der Merkmalsausprägungen der einzelnen Klassen

untereinander, insbesondere der Merkmalsausprägungen der Klasse *Baum* mit der Klasse *Niedrige Vegetation* und der Klasse *Versiegelte Fläche* mit der Klasse *Sonstiges*. Das Problem der Überlappung der Klasse *Baum* mit der Klasse *Niedrige Vegetation* wurde bereits diskutiert. Die Überlappung der Klasse *Versiegelte Fläche* mit der Klasse *Sonstiges* ist im Grunde auf die zu der Klasse *Sonstiges* zugewiesene Objekte bzw. deren Merkmalsausprägungen zurückzuführen: z.B. Bürgersteige, Fußgängerwege oder Baustellen, die Merkmalsausprägungen der Klasse *Versiegelte Fläche* aufweisen, jedoch der Klasse *Sonstiges* gehören (siehe Abbildung 6.26). Aufgrund der Überlappung können die Verteilungen der betroffenen Klassen sogar in der Variante V_{SS} , in welcher der Klassifikator an den Daten derselben Domäne trainiert wurde, nicht sicher von einander getrennt werden. Die Vollständigkeit der Klasse *Baum* liegt bei nur 54.0% ($F1$ -Maß bei 59.4%) und der Klasse *Sonstiges* bei 12.0% ($F1$ -Maß bei 19.3%). Die starke Überlappung der Merkmalsausprägungen einzelner Klassen in der Quelldomäne führt damit zu einer Verschlechterung der Adaption auf der Zieldomäne und einem NT. Die Merkmalsausprägungen der Klasse *Gebäude* in Abbildung 6.27 zeigen keine starke Überlappung mit den anderen Klassen. Allerdings weist diese Klasse in den Bilddaten der Kachel 07_07 große Gebäudeblöcke mit einer relativ ähnlichen Höhe auf, die in einer relativ starken und kompakten Konzentration der Merkmalsausprägungen bei größeren $nDOM$ -Werten und kleinen $nDVI$ -Werten resultieren (siehe Abbildung 6.27). Dabei ist eine solche Verteilung der Merkmalsausprägungen der Klasse *Gebäude* für viele andere Bildkacheln in dem Datensatz untypisch. Der DA-Algorithmus scheint damit relativ gut umgehen zu können (evtl. auch unter Zuhilfenahme der anderen Merkmale): der $F1$ -Wert steigt im Mittel über die 19 Tests von 90.5% in der Variante V_{ST} auf 91.5% in der Variante V_{DA} , wobei die Vollständigkeit und Korrektheit im Mittel bei 90.3% bzw. 92.9% liegen. Ein Ausschluss der Tests mit dieser Kachel in der Quelldomäne aus der Testreihe würde zu einer mittleren Verbesserung der OA_{DA} von 75.2% auf 75.5% bzw. Verbesserung der ΔOA_{DA} von -0.2% auf -0.1% (der Median bleibt unverändert bei 0.2%) über die gesamte Testreihe führen.

3CityDS. Die Analyse der Ergebnisse für den 3CITYDS Datensatz ist insofern interessant, als dieser gleich 3 Testgebiete beinhaltet. Die Aufnahmen selbst unterscheiden sich aufgrund der verschiedenen Bildflugzeiten in den Beleuchtungsverhältnissen, wobei die Bodenpixelgröße (GSD) der Aufnahmen mit 20 cm sich von den Testgebieten *Vaihingen* und *Potsdam* unterscheidet. Die Städte Buxtehude, Hannover und Nienburg weisen außerdem unterschiedliche Bebauungsstruktur und Grad der Urbanisierung auf. Die Auswertung der Daten aus Tabelle 6.20 zeigt mit dem Median und Mittelwert ΔOA_{DA} von -0.1% bzw. -0.7% ähnliche Werte zu dem *Vaihingen* Datensatz. Allerdings liegen die Werte für ΔOA_{TD} mit 10.4% und 13.6% für Median bzw. Mittelwert deutlich über jenen vom *Vaihingen*. Dieses Verhalten von ΔOA_{DA} und ΔOA_{TD} ist auf eine größere Varianz in den Daten selbst (größere Unterschiede zwischen den Domänen) zurückzuführen. Es ist allerdings nicht auszuschließen, dass die Auswahl der Merkmale sowie Optimierung der Parameter speziell für diesen Datensatz zu einer signifikanten Verbesserung der Werte führen könnten.

Die klassenspezifische Qualitätsmaße nach der DA fallen durch vergleichsweise etwas schlechtere Werte für die Klassen *Versiegelte Fläche* ($F1$ von 68.0%), *Gebäude* ($F1$ von 79.7%) und *Niedrige Vegetation* ($F1$ von 53.9%) auf (siehe Tabelle 6.20). Außer der größeren Diskrepanz zwischen

den Domänen liegt einer der Gründe dafür in der Qualität der Trainingsdaten selbst, wodurch dieser Datensatz auch in der Variante V_{TT} , in der der Klassifikator an denselben Daten unter Verwendung der Labels trainiert wird, schlechter als die anderen Datensätze abschneidet. So sind in den Orthophoto-Daten der drei Testgebiete die Fassaden der Gebäude deutlich zu erkennen (siehe Abbildung 6.28); Hier wurde zur Entzerrung der Orthophotos das DGM als Grundlage verwendet. Zudem wurden die Referenzdaten auf Basis von Orthophotos erstellt. Die Orthophotos sind jedoch aufgrund der Verwendung eines DGM zu ihrer Herstellung mit den vorliegenden DOM-Daten nicht exakt koreferenziert. Als Folge entstehen an den Klassengrenzen Merkmalsausprägungen mit verfälschten DOM- und damit auch nDOM-Werten, wie Abbildung 6.29 zeigt. Solche Merkmalsausprägungen streuen verstärkt in Bereiche der anderen Klassen im Merkmalsraum und verhindern somit eine erfolgreiche Adaption durch die Überlappungen der jeweiligen Klassenverteilungen, wie es bereits für *Vaihingen* und *Potsdam* erläutert wurde. Es soll in diesem Kontext besonders die Qualität der Daten aus dem Testgebiet *Hannover* angesprochen werden. Außer der lokalen Verschiebung des DOM gegenüber der Referenzdaten zeigt das DOM in allen Bildkacheln des Testgebietes stufenartige Segmentartefakte; vermutlich wegen einer zu starken Regularisierung bei der Erzeugung (siehe Abbildung 6.30). Damit ist die reale Oberfläche nicht korrekt wiedergegeben. Darüber hinaus liegen die Werte des Rot-Kanals im Testgebiet *Hannover* in einem schmaleren Bereich als die Werte in den Aufnahmen von *Buxtehude* und *Nienburg*. Das führt bei der Berechnung von NDVI zu einer untypischen Verteilung der Werte. Das Problem wird durch die Normierung der NDVI-Werte gemildert, jedoch nicht gelöst. So liegt der Mittelwert der normierten NDVI-Werte im Testgebiet *Hannover* mit 0.27 für *Versiegelte Fläche* und 0.22 für *Gebäude* immer noch deutlich über die entsprechenden Werte von 0.18 bzw. 0.14 im Testgebiet *Buxtehude* oder 0.16 bzw. 0.18 im Testgebiet *Nienburg*. Aus diesem Grund weisen die Merkmalsausprägungen der Klassen *Versiegelte Fläche* und *Gebäude* im Testgebiet *Hannover* ungewöhnlich hohe NDVI-Werte auf. Dadurch streuen die Merkmalsausprägungen der beiden Klassen verstärkt in Bereiche der Vegetationsklassen im Merkmalsraum (siehe Abbildung 6.31). Es entstehen größere Überlappungsbereiche im Merkmalsraum, die eine erfolgreiche Adaption verhindern können.

Bei der Analyse der Fälle, die zu einem NT führen, fallen jene mit Kachel 131 des Testgebiets *Buxtehude* als Zieldomäne besonders auf. Es gibt insgesamt 15 Tests mit einer solchen Konstellation in der gesamten Testreihe. In diesen Tests ist der Rückgang der Genauigkeit durch DA am höchsten. Positiver Transfer wird in nur 3 von 15 Tests erreicht, wobei für einen davon die Quell- und Zieldomäne identisch sind. Der Schnitt über alle 15 Tests des Genauigkeitsverlusts ΔOA_{DA} liegt bei -5.0% . Der Mittelwert von ΔOA_{DA}^- über 12 Tests mit NT liegt bei -7.8% und von ΔOA_{DA}^+ über 3 Tests mit positivem Transfer bei 6.1% . Eine Analyse des Datensatzes $\mathfrak{D}_{\text{CityDS}}^3$ zeigt, dass Kachel 131 als einzige überwiegend aus Grünland besteht. Dementsprechend liegt der Anteil der Pixel der Klasse *Niedrige Vegetation* in der Kachel 131 bei 66% . Nach der DA reduziert sich die Qualität für die Trennung der Klasse *Baum* und *Niedrige Vegetation* in den Tests mit der Kachel 131 als Zieldomäne am meisten. Der $F1$ -Wert fiel im Mittel um 8.2% auf 59.6% für *Baum* und um 3.9% auf 72.8% für *Niedrige Vegetation*. Die einzige Klasse, für die das $F1$ -Maß sich verbessert hat, ist die Klasse *Gebäude*. Deren $F1$ -Wert stieg im Mittel um 2.6% auf 84.1% . Eine nähere Untersuchung hat ergeben, dass die Klasse *Niedrige Vegetation*

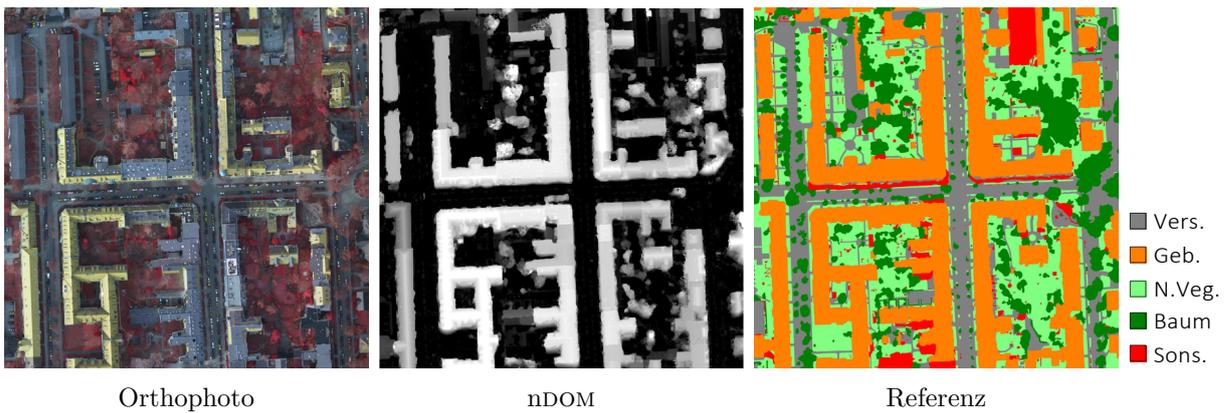


Abbildung 6.26: Orthophoto, nDOM und Referenz der Kachel 07_07 aus dem *Potsdam* Datensatz. Bei den Tests mit dieser Kachel als Quelldomäne führt die DA zum höchsten Genauigkeitsverlust.

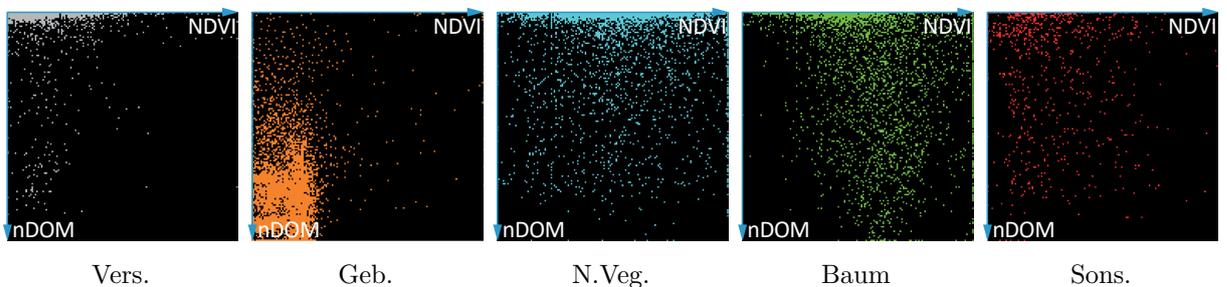


Abbildung 6.27: Merkmalsausprägungen der Kachel 07_07 (vgl. Abbildung 6.26) aus dem *Potsdam* Datensatz für die Klassen *Versiegelte Fläche* (Vers.), *Gebäude* (Geb.), *Niedrige Vegetation* (N.Veg.), *Baum* (Baum) und *Sonstiges* (Sons.). Der Merkmalsraum ist zur Visualisierung auf zwei Merkmale nDOM und NDVI reduziert. Die Klassenverteilungen offenbaren eine starke Überlappung der einzelnen Merkmalsausprägungen, insbesondere zwischen den Klassen *Baum* und *Niedrige Vegetation* sowie zwischen den Klassen *Versiegelte Fläche* und *Sonstiges*.

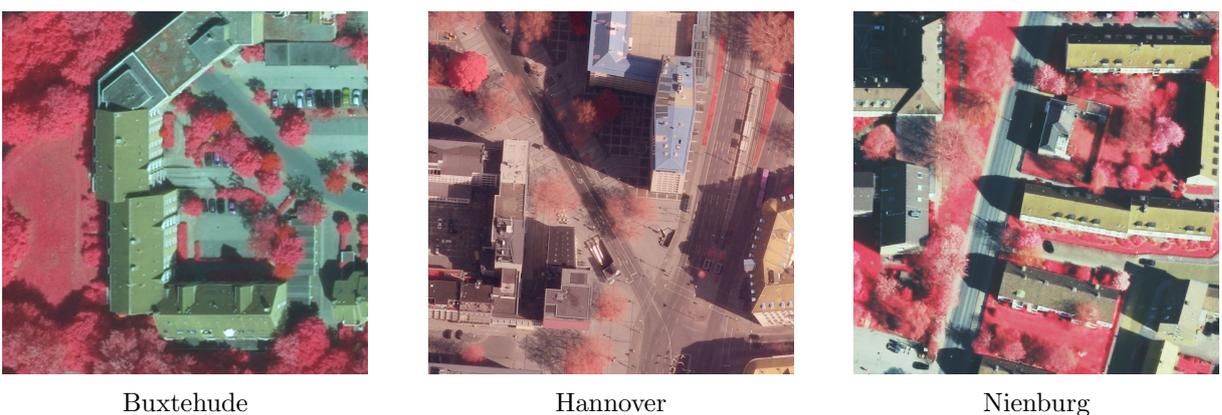


Abbildung 6.28: Verwendung der DOP statt TOP bei dem 3CITYDS Datensatz. Die Bilder zeigen je ein Ausschnitt aus dem Orthophoto der Testgebiete *Buxtehude*, *Hannover* bzw. *Nienburg*.

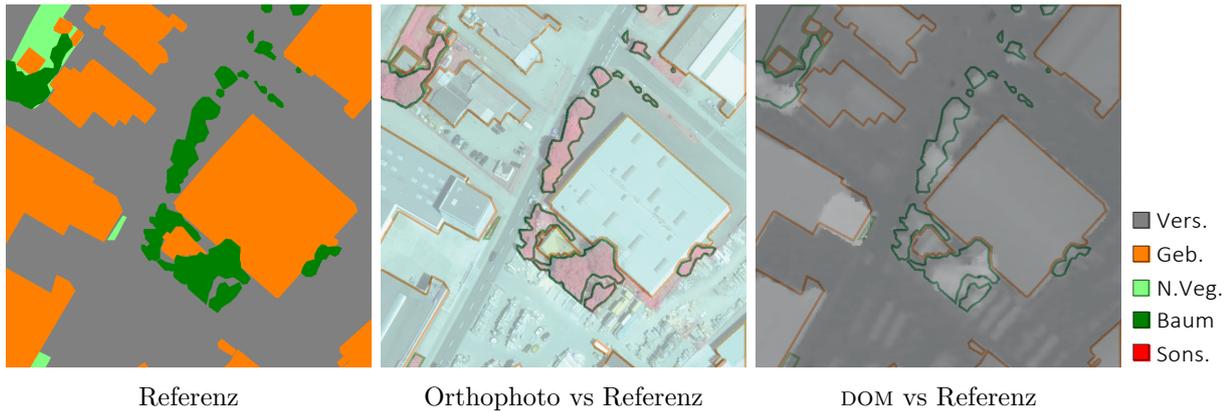


Abbildung 6.29: Gegenseitige lokale Verschiebung der DOM- und Bilddaten am Beispiel der Kachel 133 des Testgebiets *Buxtehude*. Die Abbildung zeigt einen Ausschnitt der Referenzdaten und deren Überlagerung (als Kontur der Referenz) mit dem Orthophoto und dem DOM. Eine lokale Verschiebung ist bei der Überlagerung mit dem DOM an Klassengrenzen deutlich zu erkennen, während die Überlagerung mit dem Orthophoto exakt übereinstimmt.

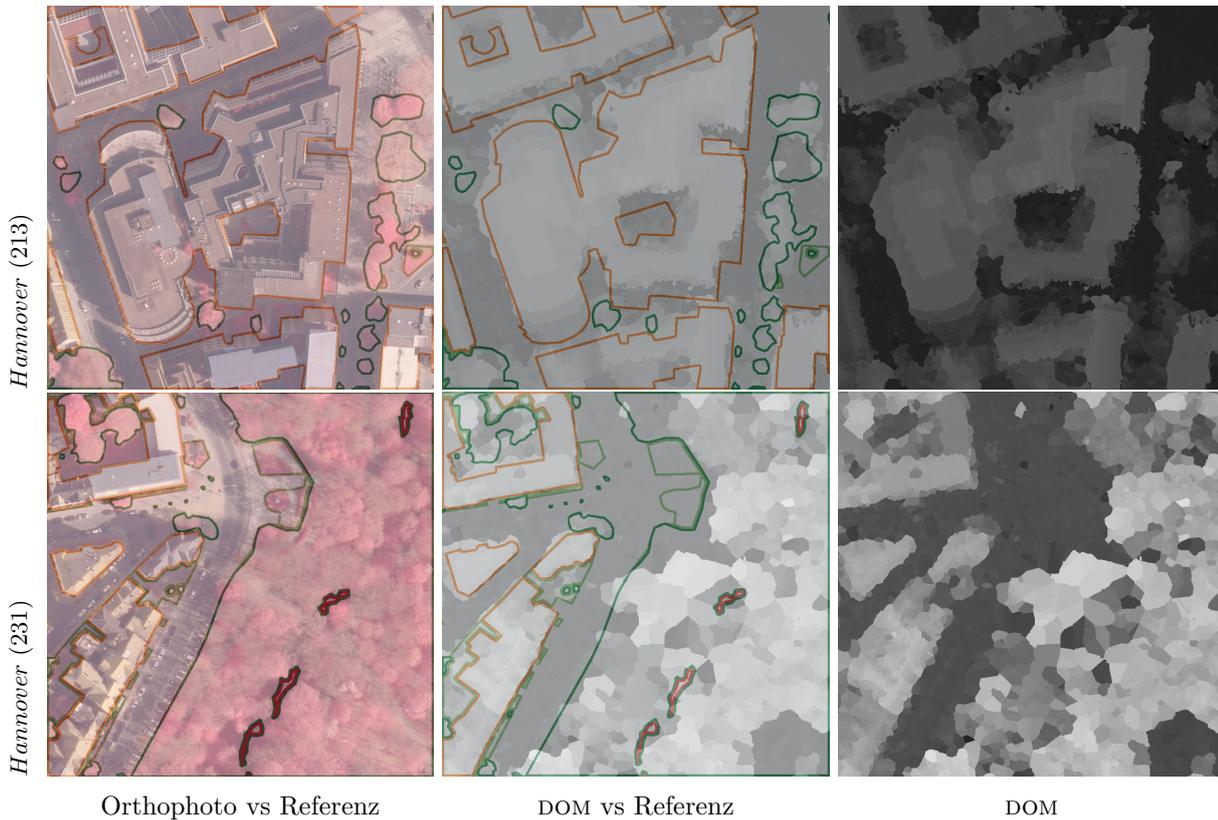


Abbildung 6.30: Beispiel für die Qualität der Daten aus dem Testgebiet *Hannover* des 3CITYDS Datensatzes. Die Abbildung zeigt für je ein Ausschnitt aus der Kachel 213 bzw. 231 die Überlagerung der Referenz (als Kontur) mit dem Orthophoto und dem DOM sowie das DOM separat. Eine lokale Verschiebung des DOM gegenüber den Referenzdaten an den Klassengrenzen ist erkennbar. Außerdem sind in den DOM-Daten stufenartige Artefakte vorhanden, wodurch die reale Oberfläche und damit auch die Höhen nicht korrekt wiedergeben werden.

eine große Streuung in Bereich der großen nDOM-Werte aufweist, während die Klasse *Baum* viele Merkmalsausprägungen im Bereich der kleinen nDOM-Werte hat. Dadurch entsteht eine starke Überlappung der Ausprägungen der beiden Klassen im Merkmalsraum (siehe Abbildung 6.32), die bei der semi-überwachten Adaption ohne Labels in der Zieldomäne nicht aufgelöst werden kann. Es kann damit vermutet werden, dass für die Anwendung der DA die Verteilung der Merkmale in dieser Kachel zu unterschiedlich zu den Verteilungen aus anderen Kacheln ist und die Ähnlichkeitsbedingung nicht erfüllt ist. All dies führt dazu, dass die Adaption hier in den meisten Fällen zu NT mit einem großen Verlust der Genauigkeit führt. Wäre eine fehlerfreie Erkennung vom NT in diesem Fall möglich, wodurch die 12 Tests mit der Kachel 131 in der Zieldomäne erkannt und ausgeschlossen wären, würde dies zu einer mittleren Verbesserung der ΔOA_{DA} von -0.7% auf -0.3% über die gesamte Testreihe führen. Die Ergebnisse der meisten Tests würden dann in einem positiven Transfer mit dem Median ΔOA_{DA} von 0.1% resultieren.

Weiterhin schneiden die Kacheln 211 und 222 des Testgebietes *Hannover* als Zieldomänen mit einem großen Verlust in der Genauigkeit ab. Ein NT wird in 11 bzw. 12 von 15 Tests für die Kacheln 211 und 222 erreicht, dabei geht nach der DA die Genauigkeit ΔOA_{DA} von je 3.7% bzw. 4.4% im Mittel verloren. Der Mittelwert von ΔOA_{DA}^- liegt jeweils bei -5.6% bzw. -6.0% und von ΔOA_{DA}^+ jeweils bei 1.5% bzw. 2.1% für die Kacheln 211 und 222. Ein Ausschluss der Tests, die in einem NT resultieren, mit den beiden Kacheln in der Zieldomäne aus der Testreihe würde zu einer Verbesserung von ΔOA_{DA} von -0.7% auf -0.2% über die gesamte Testreihe führen. Auch in diesem Fall würden danach die meisten Tests in einem positiven Transfer mit dem Median ΔOA_{DA} von 0.1% resultieren. Während der Untersuchung wurde festgestellt, dass außer der schlechten Qualität der Bilddaten der Interpretationsschlüssel in den Referenzdaten mitverantwortlich ist. Dieser Fall ist sehr ähnlich zu jenem mit der Kachel 17 aus dem *Vaihingen* Datensatz. Statt Weingarten wurde hier in den Referenzdaten das Schienennetz der Bahn der Klasse *Niedrige Vegetation* zugeordnet (siehe Abbildung 6.33), wobei die Merkmalsausprägungen dieser Klasse eher die Eigenschaften der Klasse *Versiegelte Fläche* oder *Gebäude* aufweisen. Dies zeigt die Verteilung der Merkmalsausprägungen der Klasse *Niedrige Vegetation* aus Abbildung 6.31 am Beispiel der Kachel 222. Dabei gehören die Merkmalsausprägungen des Clusters in dem linken oberen Quadranten dem Schienennetz der Bahn. Beim Vergleich mit den anderen Verteilungen in der Abbildung ist zu erkennen, dass der Cluster zwischen den Verteilungen der Klassen *Versiegelte Fläche* und *Gebäude* liegt. Dadurch entsteht eine Überlappung der Verteilungen im Merkmalsraum. Sogar bei einem Training des Klassifikators an gelabelten Daten derselben Kachel 222 kommt man für *Niedrige Vegetation* nur auf einen Wert der Vollständigkeit von 58.4% (64.3% für $F1$ -Maß). Bei der DA mit einer der Kacheln 211 oder 222 als Zieldomäne werden nach der Adaption die klassenspezifische Qualitätsmaße der beiden überlappenden Klassen *Versiegelte Fläche* und *Gebäude* beeinträchtigt; Im Mittel verlieren sie je 3.5% und 3.1% mit der Kachel 211 bzw. 2.7% und 4.1% mit der Kachel 222 als Zieldomäne.

Pool2. Der POOL2 ist nach dem 3CITYDS ein weiterer Datensatz, in dem der Transfer zwischen zwei Gebieten (hier: *Vaihingen* und *Potsdam*) getestet wurde. Die beiden Testgebiete unterscheiden sich hinsichtlich des Grades der Urbanisierung sowie Bebauungsstruktur: kleine, niedrige und freistehende Häuser und Gebäude bei *Vaihingen* oder große Gebäudeblöcke und

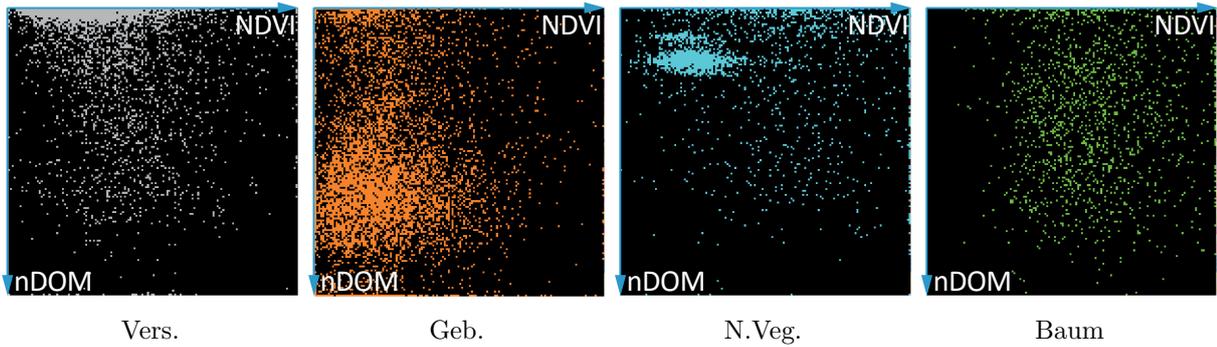


Abbildung 6.31: Merkmalsausprägungen von der Kachel 222 aus dem Testgebiet *Hannover* aufgeteilt nach den Klassen *Versiegelte Fläche* (Vers.), *Gebäude* (Geb.), *Niedrige Vegetation* (N.Veg.), *Baum* (Baum) und *Sonstiges* (Sons.). Der Merkmalsraum ist zur Visualisierung auf zwei Merkmale nDOM und NDVI reduziert. Die Merkmalsausprägungen der Klassen *Versiegelte Fläche* und *Gebäude* offenbaren eine Streuung in Bereiche hoher NDVI-Werte. Dies resultiert in einer starken Überlappung der Merkmalsausprägungen obiger Klassen mit jenen der Klassen *Niedrige Vegetation* und *Baum*.

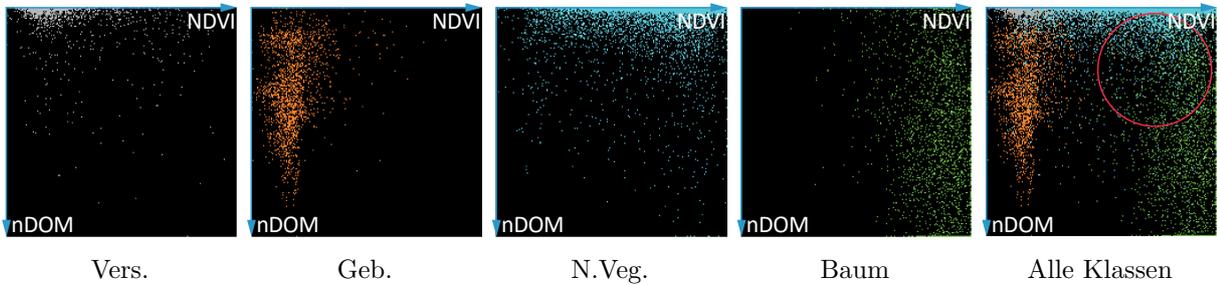


Abbildung 6.32: Merkmalsraum mit Merkmalsausprägungen von der Kachel 131 aus dem Testgebiet *Buxtehude*. Die Abbildung zeigt je eine Verteilung der Merkmalsausprägungen pro Klasse sowie eine gemeinsame Verteilung der Klassen: *Versiegelte Fläche* (Vers.), *Gebäude* (Geb.), *Niedrige Vegetation* (N.Veg.) und *Baum* (Baum). Der Merkmalsraum ist zur Visualisierung auf zwei Merkmale nDOM und NDVI reduziert. Die Verteilung der Klasse *Niedrige Vegetation* weist eine große Streuung in Bereich der großen nDOM-Werte auf, während die Klasse *Baum* viele Merkmalsausprägungen im Bereich der kleinen nDOM-Werte hat. Dadurch entsteht eine starke Überlappung der Merkmalsausprägungen der beiden Klassen im markierten Bereich der gemeinsamen Verteilung.



(a) Kachel 211: Orthophoto & Referenz

(b) Kachel 222: Orthophoto & Referenz

Abbildung 6.33: Das Orthophoto und die Referenz der Kacheln 211 (a) und 222 (b) des Testgebiets *Hannover*. Der Interpretationsschlüssel der Referenz legt für das Schienennetz der Bahn die Klasse *Niedrige Vegetation* fest. Diese Interpretation führt zu Fehlern im Verlauf der Adaption, da das Schienennetz die Eigenschaften anderer Klassen in den Bilddaten vorweist.

lange, schmale Straßen bei *Potsdam*. Die Bilder weisen außerdem verschiedene saisonale Effekte auf: vitale Vegetation bei *Vaihingen* im Hochsommer und fortschreitendes Verwelken der Vegetation in der Herbstmitte bei *Potsdam*. Die allgemeine Darstellung der Ergebnisse aus Kapitel 6.3.3 hat bereits gezeigt, dass auch für diesen Datensatz ein positiver Transfer möglich ist. Die Auswertung der Ergebnisse von ΔOA_{DA} für POOL2 aus Tabelle 6.20 weist einen relativ starken Abfall der Genauigkeit nach der DA auf. Dabei liegt der Mittelwert von ΔOA_{DA} über die gesamte Testreihe bei -1.2% , während der Median von ΔOA_{DA} -0.3% beträgt. Ein großer Unterschied zwischen dem Mittelwert und Median weist auf einige Ausreißer in der Testreihe mit einem starken Verlust der Genauigkeit ΔOA_{DA} nach der DA hin. Der POOL2 Datensatz weist im Vergleich zu 3CITYDS stärkere Ausprägung der saisonalen Effekte auf, da die Aufnahmen für alle Testgebiete beim 3CITYDS Datensatz im Unterschied zu POOL2 zur selben Jahreszeit (Frühling), wenn auch nicht im selben Jahr, gemacht wurden. Ein schlechteres Ergebnis von ΔOA_{DA} beim POOL2 Datensatz im Vergleich zum 3CITYDS Datensatz deutet darauf hin, dass stärkere saisonale Effekte eine größere negative Auswirkung auf das Ergebnis der DA haben (siehe Tabelle 6.20).

Bei der Analyse der Fälle, die zu einem NT führen, fallen wieder jene mit der Kachel 17 aus dem Testgebiet *Vaihingen* als Quelldomäne auf; das Problem mit Weingarten in der Kachel 17 wurde bereits im Abschnitt über *Vaihingen* ausführlich erläutert. Es gibt hier insgesamt 37 Tests mit dieser Kachel in der Rolle der Quelldomäne in der Testreihe, welche beim POOL2 Datensatz aus 1369 Tests besteht. Ein positiver Transfer wird in nur 9 Tests erreicht. Im Mittel über 37 Test reduziert sich das Genauigkeitsmaß ΔOA_{DA} um -4.9% pro Test und der Mittelwert von ΔOA_{TD} beträgt 17.2% pro Test. Der Mittelwert von ΔOA_{DA}^+ liegt bei 2.6% , während der Mittelwert von ΔOA_{DA}^- bei -7.3% liegt. Dabei wird die Qualität der Adaption im Mittel bei den Klassen *Versiegelte Fläche* und *Niedrige Vegetation* am meisten beeinträchtigt. Der Rückgang des $F1$ -Wertes in der Variante V_{DA} gegenüber der Variante V_{ST} liegt bei -7.5% für die Klasse *Versiegelte Fläche* bzw. bei -5.7% für die Klasse *Niedrige Vegetation*. Dieser Verlust ist (abgesehen von der Problemstelle mit dem Weingarten in Kachel 17) auf saisonale Effekte zurückzuführen, wenn die Zieldomäne aus dem Testgebiet *Potsdam* kommt. So verschiebt sich die Verteilung der Merkmalsausprägungen der Klasse *Niedrige Vegetation* bzw. der Klasse *Baum* im Merkmalsraum in Richtung kleinerer NDVI-Werte aufgrund der abnehmenden Vitalität der Vegetation bei *Potsdam* (Aufnahmen im Herbst). Dadurch nimmt die Überlappung zwischen den Verteilungen der Klassen *Versiegelte Fläche* und *Niedrige Vegetation* stark zu; diese Überlappung kann dann während der DA nicht kompensiert werden.

Weiterhin fällt auch die Kachel 07.13 des Testgebiets *Potsdam* in der Rolle der Zieldomäne negativ auf. Ein positiver Transfer mit dieser Kachel als Zieldomäne wird nur in 3 von 37 Tests erreicht, und zwar nur in den Tests, in denen die Quelldomäne auch aus dem Testgebiet *Potsdam* stammt. Dabei beträgt ΔOA_{DA} im Mittel über 37 Tests -7.8% , wobei der Mittelwert von ΔOA_{TD} bei 18.5% liegt. Der Mittelwert von ΔOA_{DA}^+ liegt bei 0.9% , während der Mittelwert von ΔOA_{DA}^- bei -8.6% liegt. Der $F1$ -Wert nach der Adaption fällt gegenüber der Variante V_{ST} vor der Adaption für die Klasse *Versiegelte Fläche* um 9.2% , für *Gebäude* um 3.3% und für *Niedrige Vegetation* um 10.9% . Für die Klassen *Baum* und *Sonstiges* steigt der $F1$ -Wert

leicht um 1.7%. Die Untersuchung der Klassenverteilungen aus Abbildung 6.34 zeigt eine starke Überlappung der einzelnen Merkmalsausprägungen, insbesondere zwischen der Klasse *Baum* und der Klasse *Niedrige Vegetation*, bzw. zwischen der Klasse *Versiegelte Fläche* und der Klasse *Sonstiges* sowie der Klasse *Gebäude*. Die klassenspezifischen Qualitätsmaße bei der Klassifikation der Kachel 07_13 mit dem Klassifikator, der zuvor an gelabelten Daten ebendieser Kachel angelernt wurde, deutet bereits auf die Schwierigkeiten bei der Wiedererkennung der Klassen *Niedrige Vegetation* ($F1$ -Wert: 71.6%), *Baum* ($F1$ -Wert: 60.8%) und *Sonstiges* ($F1$ -Wert: 71.3%) hin. Das und die Auswirkungen der Unterschiede zwischen den Domänen, wie gegenseitige Verschiebung der einzelnen Klassenverteilungen im Merkmalsraum (vgl. Abbildung 6.22 und 6.34), z.B. aufgrund von saisonalen Effekten, sind die wesentlichen Gründe für einen NT in diesem Fall. Hätte man den NT in den beiden Fällen erkennen und ausschließen können, so würde das zu einer mittleren Verbesserung der OA_{DA} von 73.5% auf 73.9% bzw. Verbesserung der ΔOA_{DA} von -1.2% auf -0.9% (Median: -0.2%) für die restlichen 1308 Tests führen. Der Mittelwert der ΔOA_{TD} würde sich um 0.5% auf 8.9% verbessern.

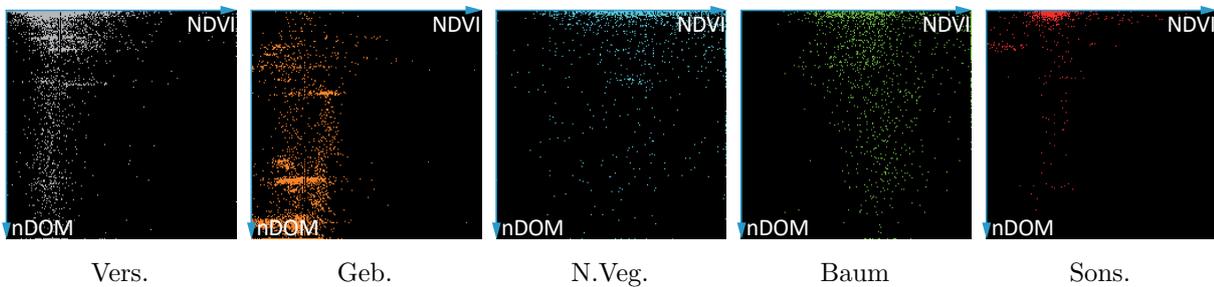


Abbildung 6.34: Merkmalsausprägungen für Kachel 07_13 aus dem Testgebiet *Potsdam* für die Klassen *Versiegelte Fläche* (Vers.), *Gebäude* (Geb.), *Niedrige Vegetation* (N.Veg.), *Baum* (Baum) und *Sonstiges* (Sons.). Der Merkmalsraum ist zur Visualisierung auf zwei Merkmale nDOM und NDVI reduziert. Die Klassenverteilungen offenbaren eine starke Überlappung der einzelnen Merkmalsausprägungen untereinander, insbesondere zwischen *Baum* und *Niedrige Vegetation*, bzw. *Versiegelte Fläche* und *Sonstiges* sowie *Gebäude*.

Zugleich und ungeachtet dessen, dass die Kachel 07_13 aus dem Testgebiet *Potsdam* in der Zieldomäne fast ausschließlich zu einem NT führt, verhilft sie in der Rolle der Quelldomäne zu einem positiven Transfer in 35 aus 37 Tests. Diese Tatsache bestätigt die These, dass die Symmetrie der Wissensübertragung in realen Anwendungen nicht immer eingehalten werden kann [Eaton et al., 2008]. Es wird dabei über die 37 Tests eine positive Entwicklung der Genauigkeit nach DA mit ΔOA_{DA} von 3.2% im Mittel pro Test erreicht. Der Mittelwert von ΔOA_{DA}^+ über 35 Tests liegt bei 3.5%, während der von ΔOA_{DA}^- über 2 Tests bei -1.5% liegt. Auf die klassenspezifischen Qualitätsmaße für die Kachel 07_13 wurde bereits im vorherigen Abschnitt detailliert eingegangen; der zugehörige 2D-Merkmalsraum ist in Abbildung 6.34 zu finden. Die beiden Ziel-Kacheln 02_12 und 02_14, mit denen die DA zu einem NT führt, kommen ebenso aus dem Testgebiet *Potsdam*. Die Verteilungen der Merkmalsausprägungen der Quelldomäne 07_13 sowie der beiden Ziel-Kacheln 02_12 und 02_14 sind in Abbildung 6.35 dargestellt. In der Variante mit 02_12 in der Zieldomäne wurde ein leichter NT mit ΔOA_{DA} von -0.7% erzielt. Dabei wurde fast ausschließlich die Qualität der Klasse *Niedrige Vegetation* beeinträchtigt, deren $F1$ -Wert in der Variante V_{DA} gegenüber der V_{ST} um 2.2% fiel. Der Grund liegt in einer starken

Überlappung der Merkmalsausprägungen im Merkmalsraum der Zieldomäne der Klasse *Niedrige Vegetation* mit der Klasse *Baum*, die im Bereich der niedrigen nDOM-Werte untypische viele Merkmalsausprägungen aufweist. Die Merkmalsausprägungen der Klasse *Baum* bilden dabei im rechten oberen Quadranten des Merkmalsraums einen leicht zu erkennenden Cluster (siehe Abbildung 6.35, Kachel 02_12). Ausgehend von der Verteilung der Merkmalsausprägungen der Klasse *Baum*, wird der Bereich um diesen Cluster im Merkmalsraum während der DA offensichtlich der Klasse *Baum* zugeteilt, wodurch ihr $F1$ -Wert nach der DA stark um 12.7% auf 54.1% steigt. Der Zuwachs wird in erster Linie durch Verbesserung der Vollständigkeit von 29.9% auf 51.1% erzielt. Einzelne Häuser weisen außerdem Vegetation auf den Dächern auf, welche sich in der ungewöhnlichen Verteilung der Merkmale der Klasse *Gebäude* widerspiegelt. Trotz der Unterschiede in den Verteilungen der Klasse *Gebäude* ist es der DA gelungen, den $F1$ -Wert für diese Klasse um 8.2% auf 78.6% zu verbessern. In der Variante mit 02_14 in der Zieldomäne wurde ein NT mit ΔOAD_A von -2.2% erzielt. Dabei fiel der $F1$ -Wert der Klasse *Versiegelte Fläche* um -18.7% auf 48.6% und jener der Klasse *Gebäude* um -13.3% auf 57.2% nach der DA, während das $F1$ -Maß der Klassen *Niedrige Vegetation* um 4.2% auf 50.8% und *Baum* um 1.5% auf 68.8% zugenommen hat. Der Verlust der Qualität kann durch die Unterschiede in den Verteilungen der Merkmalsausprägungen der Klassen *Versiegelte Fläche* und *Gebäude* zwischen der Quell- zu Zieldomäne begründet werden (siehe Abbildung 6.35). So beinhaltet die Kachel 02_14 im Unterschied zur Kachel 07_13 überwiegend niedrige Häuser. Zugleich weisen untypisch viele Merkmalsausprägungen der Klasse *Versiegelte Fläche* in der Kachel 07_13 relativ große nDOM-Werte auf. Es ist zu vermuten, dass die Ähnlichkeitsbedingung hier nicht erfüllt ist, weil die Verteilungen der Merkmalsausprägungen der Klassen *Versiegelte Fläche* und *Gebäude* zwischen der Quell- zu Zieldomäne zu unterschiedlich sind. Der relativ große Verlust der klassenspezifischen Qualitätsmaße der Klassen *Versiegelte Fläche* und *Gebäude* ist unter anderem auf die Anzahl der Stichproben in der jeweiligen Klasse zurückzuführen. Der Anteil der Gesamtstichproben aus der Klasse *Versiegelte Fläche* in der Kachel 07_13 liegt bei 16% und aus der Klasse *Gebäude* bei nur 7%. Solche unterrepräsentierte Merkmalsausprägungen in der Zieldomäne können aufgrund der Unterschiede zwischen der Quell- und Zieldomäne einfacher einer falschen Klasse während der DA zugeteilt werden, da die Semi-Labels auf Basis einer lokalen Analyse (von K -NN und aus dem aktuellen Zustand des Klassifikators) zugewiesen werden. Ausgenommen die beiden Kacheln 02_12 und 02_14 als Zieldomänen, scheint die Verteilung der Daten der Kachel 07_13 und der darauf angelegte initiale Klassifikator eine optimale Ausgangslage für die nachfolgende DA darzustellen. Ein exemplarisches Ergebnis für die DA mit der Kachel 07_13 des Testgebiets *Potsdam* als Quelldomäne und der Kachel 30 des Testgebiets *Vaihingen* als Zieldomäne ist in Abbildung 6.36 dargestellt. In diesem Fall wurde ein positiver Transfer mit ΔOAD_A von 9.4% erreicht. Trotz der Unterschiede aufgrund der saisonalen Effekte, in der Bebauungsstruktur beider Städte und in der Aufnahmesensorik hat sich die Qualität der Trennung der Klassen nach der DA in diesem Beispiel relativ zu der Variante V_{ST} verbessert.

Weiterhin wird auch für die Kachel 35 aus dem Testgebiet *Vaihingen* in der Rolle als Zieldomäne überwiegend ein positivem Transfer erreicht. Diese Kachel ist bereits positiv bei der Analyse der Ergebnisse für den *Vaihingen* Datensatz aufgefallen und wurde dort ausführlich beschrieben. Hier wird in 29 aus 37 Tests mit dieser Kachel in der Zieldomäne ein positiver Transfer erzielt.

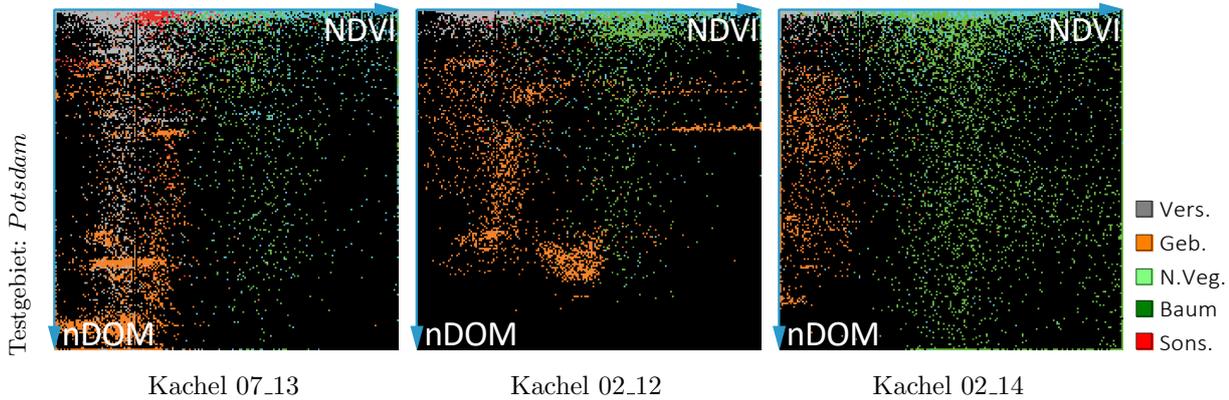


Abbildung 6.35: Verteilung der Merkmalsausprägungen aus den Kacheln 07_13, 02_12 und 02_14 aus dem Testgebiet *Potsdam* im Merkmalsraum (zur Visualisierung reduziert auf zwei Merkmale nDOM und NDVI). Die Bilder zeigen die Merkmalsverteilungen der Kacheln 02_12 und 02_14, die sich von Verteilung der Merkmalsausprägungen der Kachel 07_13 unterscheiden. Eine Adaption ausgehend von der Kachel 07_13 als Quelldomäne auf die Kachel 02_12 oder 02_14 als Zieldomäne schlägt aufgrund der Unterschiede fehl und führt zum NT.

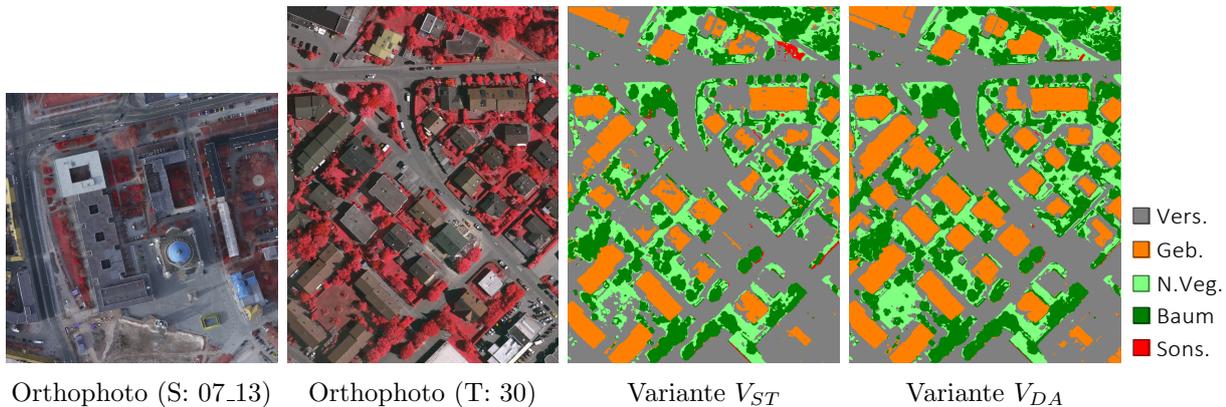


Abbildung 6.36: Exemplarisches Ergebnis der DA für den POOL2 Datensatz mit der Kachel 07_13 aus dem Testgebiet *Potsdam* (siehe Abbildung 6.35) als Quelle und der Kachel 30 des Testgebiets *Vaihingen* als Zieldomäne. Exakte Werte zur Beurteilung der Qualität der Adaption für das Beispiel sind in Tabelle 6.26 zusammengefasst.

Tabelle 6.26: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.36. Dabei wird hier nach der DA ein positiver Transfer mit $\Delta OA_{DA} = 9.4\%$ erreicht.

	$F1$ [%]					OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
	Vers.	Geb.	N.Veg.	Baum	Sons.			
V_{TT}	87.0	92.8	71.9	84.9	0.0	84.6		
V_{ST}	70.3	66.6	53.6	76.0	0.0	67.3	9.4	7.9
V_{DA}	78.6	84.3	61.0	79.6	0.0	76.7		

Der Mittelwert von ΔOA_{DA} über die 37 Tests liegt dabei bei 2.5%. Der Mittelwert von ΔOA_{DA}^+ über 29 Tests mit positivem Transfer liegt bei 3.4%, während der von ΔOA_{DA}^- über 2 Tests bei -0.6% liegt. Die klassenspezifischen Qualitätsmaße verhalten sich zu der Beschreibung aus dem Abschnitt über *Vaihingen* Datensatz relativ ähnlich. Der *F1*-Wert fiel nur für die Klasse Niedrige Vegetation, und zwar um -1.2% auf 62.7%. Zugleich stieg er für die Klasse *Gebäude* am meisten, nämlich um 6.5% auf 87.1%.

Pool5. Der POOL5 Datensatz beinhaltet alle 5 Testgebiete: *Vaihingen*, *Potsdam*, *Buxtehude*, *Hannover* und *Nienburg*. Die Testgebiete sind räumlich disjunkt und haben unterschiedliche Aufnahmezeiten, die Städte haben unterschiedliche Bebauungsstruktur und Grad der Urbanisierung, die Aufnahmen haben teilweise verschiedene Bodenpixelgröße und weisen aufgrund der verschieden Bildflugzeiten unterschiedliche Beleuchtungsverhältnisse und saisonale Effekte (z.B. bei Ausprägung der Vegetation und Belaubung der Bäume) auf. Die allgemeine Darstellung der Ergebnisse aus Kapitel 6.3.3 hat bereits gezeigt, dass auch für diesen Datensatz ein positiver Transfer möglich ist. Die Auswertung der Ergebnisse von ΔOA_{DA} für POOL5 aus Tabelle 6.20 weist dennoch einen relativ starken Abfall der Genauigkeit nach der DA. Dabei liegt der Mittelwert von ΔOA_{DA} mit -1.0% leicht über dem Wert vom POOL2 Datensatz, während der Median mit -0.3% nur leicht unter dem Niveau von 3CITYDS (-0.1%) und *Vaihingen* (-0.2%) liegt. Ein Unterschied zwischen dem Mittelwert und Median weist auf einige Ausreißer in der Testsreihe mit einem starken Verlust der Genauigkeit ΔOA_{DA} nach der DA hin. Der Verlust der Genauigkeit aufgrund der fehlenden Labels in der Zieldomäne ΔOA_{TD} erreicht mit einem Median von 11.2% den größten Wert unter allen Datensätzen, wobei der Mittelwert mit 12.7% leicht besser als der Mittelwert von 13.6% für den 3CITYDS Datensatz ist. Wegen der unterschiedlichen GSD innerhalb des POOL5 Datensatzes deutet ein schlechteres Ergebnis für ΔOA_{TD} im Vergleich zu POOL2 und 3CITYDS darauf hin, dass die Unterschiede in der Bodenpixelgröße sich negativ auf das Ergebnis der DA auswirken.

Bei der Analyse der Fälle, die zu einem NT führen, fallen wieder die Kacheln 07_13 des Testgebiets *Potsdam* in der Rolle der Zieldomäne und die Kachel 17 des Testgebiets *Vaihingen* in der Rolle der Quelldomäne auf. Auf die Eigenschaften dieser Kacheln wurde bereits in den vorherigen Abschnitten detailliert eingegangen, deswegen wird hier nur die entsprechende Statistik für den POOL5 Datensatz kurz vorgestellt. In 52 Tests, die mit der jeweiligen Kachel möglich sind, wird ein NT in 49 Fällen mit der Kachel 07_13 in der Zieldomäne und in 37 Tests mit der Kachel 17 in der Quelldomäne erreicht. Dabei beträgt im Mittel über 52 Tests $\Delta OA_{DA} = -8.1\%$ (ΔOA_{DA}^- : -8.7%) mit der Kachel 07_13 als Zieldomäne bzw. $\Delta OA_{DA} = -4.2\%$ (ΔOA_{DA}^- : 7.1%) mit der Kachel 17 als Quelldomäne. Weiterhin ist in den Tests mit der Kachel 131 des Testgebiets *Buxtehude* in der Rolle der Zieldomäne der Genauigkeitsverlust nach der DA am höchsten. Ein positiver Transfer wird in nur 7 von 52 Tests mit einer solchen Konstellation erreicht. Im Mittel über die 52 Tests beträgt $\Delta OA_{DA} = -10.8\%$. Der Mittelwert von ΔOA_{TD} über die 52 Tests beträgt 28.9%. Der Mittelwert von ΔOA_{DA}^+ über 7 positive Tests liegt bei 4.7% und von ΔOA_{DA}^- über 45 Tests mit einem NT bei -13.2%. Dabei geht die Qualität der Adaption im Mittel bei den Klassen *Niedrige Vegetation* und *Baum* am meisten verloren. Der *F1*-Wert sinkt um 11.7% auf 63.8% in der Variante V_{DA} gegenüber der Variante V_{ST} für die Klasse *Niedrige Vegetation* bzw. um 15.1% auf 46.1% für *Baum*. Der *F1*-Wert der Klasse *Versiegelte Fläche*

sinkt nur um 2.4% auf 60.3, $F1$ -Wert steigt sogar um 0.6% auf 80.7% für die Klasse *Gebäude*. Zur einer tiefergehenden Analyse der Ursachen wurden die Bilddaten untersucht (siehe Abbildung 6.37). Kachel 131 zeigt als einzige ein ländliches Gebiet mit kleinen alleinstehenden Häusern und großen landwirtschaftlich genutzten Flächen. Weiterhin weisen die Merkmalsausprägungen der Klasse *Niedrige Vegetation* eine relativ starke Überlappung mit den Ausprägungen der Klassen *Versiegelte Fläche* und *Baum*. Bei einer näheren Betrachtung kann hier zudem beobachtet werden, dass ein positiver Transfer überwiegend in den Fällen erreicht wurde, in denen das Orthophoto der Quelldomäne zu dem aus der Zieldomäne ähnliche Charakteristika aufweist. Einige exemplarische Kacheln, die als Quelldomäne zu einer positiven Adaption auf die Kachel 131 als Zieldomäne führen, sind in Abbildung 6.38 zu finden. Darunter sind auch die Kacheln aus anderen Testgebieten, die unterschiedliche Charakteristika der Aufnahmen (auch in der Bodenpixelgröße) aufweisen. Dies alles deutet darauf hin, dass der Grund für einen starken NT mit der Kachel 131 als Zieldomäne auf die Unähnlichkeit in der Verteilung der Klassen zu den meisten anderen Kacheln in dem Datensatz zurückzuführen ist. Wäre eine fehlerfreie Erkennung vom NT allein in diesen drei beschriebenen Fällen möglich, wodurch 131 Tests mit NT erkannt und ausgeschlossen wären, würde dies zu einer mittleren Verbesserung der ΔOA_{DA} von -1.0% auf -0.6% (Median bei -0.1) über die gesamte Testreihe führen. Der Mittelwert von ΔOA_{TD} würde sich um 1.6% auf 12.1% verbessern.

Weiterhin fallen bei der Analyse der DA-Ergebnisse die Kacheln 07_13 aus *Potsdam* und 231 aus *Hannover* in der Rolle der Zieldomäne sowie die Kachel 35 aus *Vaihingen* in der Rolle der Quelldomäne auf, da mit ihnen ΔOA_{DA} am größten ist und somit den höchsten Genauigkeitszuwachs durch die DA erzielt wird. Diese Kacheln wurden bereits ausführlich in den zugehörigen Abschnitten beschrieben. Aus diesem Grund wird hier nur auf die aktuelle Statistik für diese Kacheln eingegangen. Es wird für die Kacheln 07_13, 231 und 35 (in der oben beschriebenen Konstellation) ein positiver Transfer in 48, 41 bzw. 42 aus je 52 Tests erreicht. Dabei wird im Mittel für die Kachel 07_13, 231 und 35 eine Verbesserung des Genauigkeitsmaßes ΔOA_{DA} von jeweils 3.4%, 4.1% bzw. 2.7% pro Test erzielt, wobei die entsprechenden Werte von ΔOA_{DA}^+ bei 3.9%, 6.3% bzw. 3.7% liegen. Der Mittelwert von ΔOA_{TD} beträgt hier für die Kacheln 07_13, 231 und 35 jeweils 12.6%, 22.0% bzw. 7.7%. Es ist zu bemerken, dass trotz einer relativ starken Verbesserung der Genauigkeit nach der DA mit der Kachel 231 (*Hannover*) in der Zieldomäne der Wert von ΔOA_{TD} hier am schlechtesten ausfällt. Das liegt vermutlich an der Verteilung der Daten, die unähnlich zu den Verteilungen der Daten aus anderen Kacheln ist. Die Kachel 231 ist als einzige überwiegend Waldgebiet (siehe Abbildung 6.38). Außerdem haben die Artefakte des DOM sowie eine lokale Verschiebung des DOM gegenüber der Referenz der Kachel 231 (siehe Abschnitt zu 3CITYDS) einen Einfluss auf die Qualität der DA. Ein exemplarisches DA-Ergebnis mit der Kachel 231 als Quelldomäne ist in Abbildung 6.39 dargestellt. Dabei fand die Adaption zwischen zwei Gebieten statt, deren Aufnahmen unter anderem eine unterschiedliche Bodenpixelgröße aufweisen. Als Zieldomäne dient die Kachel 05_13 des Testgebiets *Potsdam*. In dem Beispiel aus der Abbildung 6.39 wird nach der DA ein positiver Transfer mit einem sehr guten Wert für ΔOA_{DA} von 11.5% erreicht. Dabei bleibt ΔOA_{TD} mit 8.7% immer noch hoch. Trotz der Unterschiede zwischen den beiden Domänen ist es der DA gelungen, einen positiven Transfer zu erreichen und den initialen Klassifikator deutlich zu verbessern.

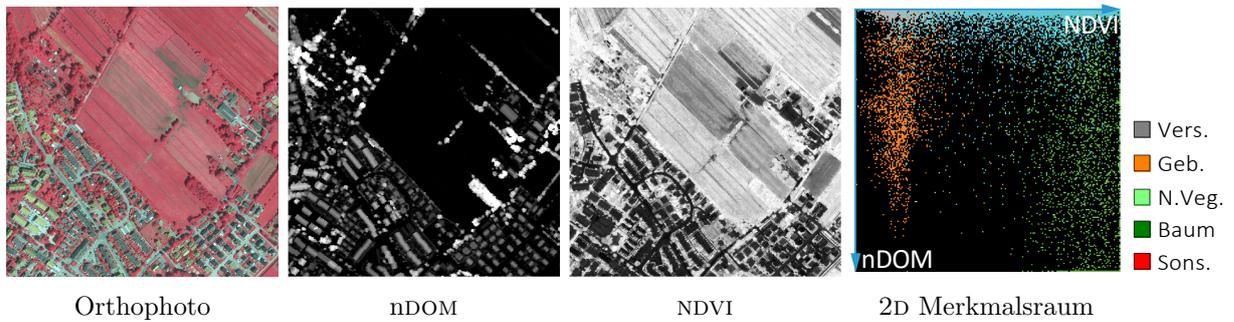


Abbildung 6.37: Orthophoto, nDOM, NDVI und Referenzdatei sowie der zugehörige Merkmalsraum (zur Visualisierung reduziert auf zwei Merkmale nDOM und NDVI) für die Kachel 131 aus dem Testgebiet *Buxtehude*. Die Kachel ist als einzige überwiegend Grünland. Der Anteil der Pixel aus der Klasse *Niedrige Vegetation* beträgt gemäß den Referenzdaten 66%. Zudem weist die Klasse *Niedrige Vegetation* eine relativ starke Überlappung ihrer Merkmalsausprägungen mit den Ausprägungen der Klassen *Versiegelte Fläche* und *Baum*. Das führt dazu, dass eine Adaption auf die Daten dieser Kachel in den meisten Fällen fehlschlägt.

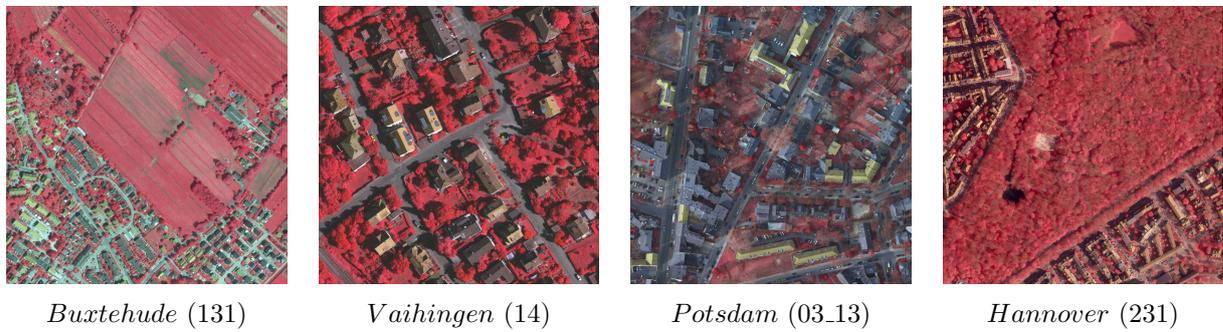


Abbildung 6.38: Orthophotos von 4 unterschiedlichen Kacheln aus Gebieten *Buxtehude*, *Vaihingen* (Ausschnitt), *Potsdam* und *Hannover*. Die Abbildung zeigt exemplarisch Kacheln mit ähnlichen Charakteristika im Orthophoto, wie meist kleine und alleinstehende Häuser oder großflächig angelegte Vegetation mit vielen Bäumen. Mit den hier abgebildeten Kacheln 231, 03.13, 14 in der Quelldomäne wird ein positiver Transfer auf die Kachel 131 erzielt, während in den meisten anderen Fällen die Adaption auf 131 fehlschlägt.

6.3.5 Analyse der Ergebnisse nach Testgebieten

Es wird hier auf die Testergebnisse der DA in dem jeweiligen Testgebiet (jeder Stadt) einzeln eingegangen. Der Schwerpunkt der Analyse liegt auf der Transferierbarkeit zwischen den einzelnen Stadtgebieten. Im ersten Teil der Analyse wird allgemeine Transferierbarkeit zwischen Kacheln der jeweiligen Testgebiete untersucht. Die Grundlage dafür bilden die Ergebnisse aus dem POOL5 Datensatz. Dabei werden die 2704 enthaltene Tests nach Testgebiet (Stadt) einsortiert und gemittelte Ergebnisse vorgestellt. Damit kann festgestellt werden, aus welchen Testgebieten Kacheln stammen, die für die Adaption gut geeignet sind bzw. in welcher Rolle (als Quell- oder Zieldomäne) sie sich für die Adaption besonders gut eignen. Im zweiten Teil der Analyse wird die Transferierbarkeit zwischen den gesamten Testgebieten untersucht. Die Grundlage dafür bildet wiederum der POOL5 Datensatz (Tabelle 6.19). Dafür werden die Stichproben aus allen Kacheln des jeweiligen Testgebietes eine Quell- bzw. eine Zieldomäne bilden, zwischen denen dann die DA stattfindet. Es entstehen insgesamt 25 Testergebnisse. Damit kann festgestellt werden, wel-

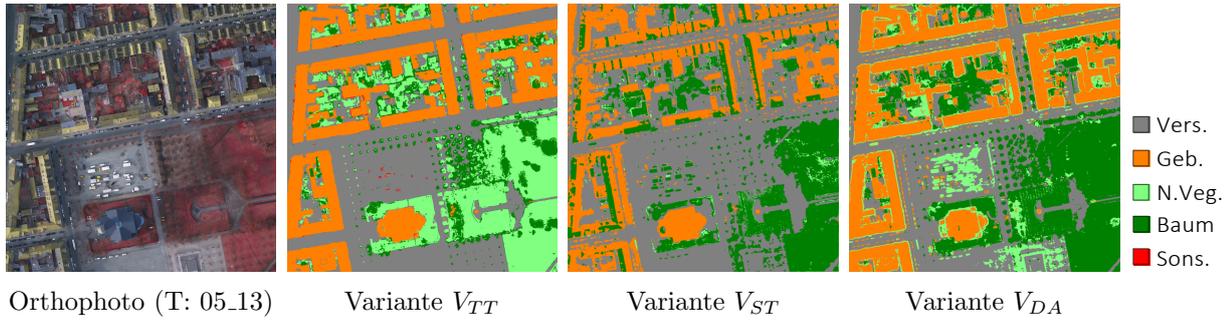


Abbildung 6.39: Exemplarisches Ergebnis der DA für den POOL5 Datensatz mit der Kachel 231 des Testgebiets *Hannover* (siehe Abbildung 6.38) als Quelldomäne und der Kachel 05_13 des Testgebiets *Potsdam* als Zieldomäne. Exakte Werte zur Beurteilung der Qualität der Adaption für das Beispiel sind in Tabelle 6.27 zusammengefasst.

Tabelle 6.27: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.39. Dabei wird nach der DA ein positiver Transfer mit ΔOA_{DA} von 11.5% erreicht.

	$F1$ [%]					OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
	Vers.	Geb.	N.Veg.	Baum	Sons.			
V_{TT}	87.6	95.1	63.4	57.9	0.4	82.3		
V_{ST}	68.3	80.6	9.6	28.5	0.0	62.2	11.5	8.7
V_{DA}	83.3	92.0	12.6	52.9	0.0	73.7		

che Testgebiete in welcher Konstellation (als Quell- oder Zieldomäne) im Allgemeinen für die Adaption am besten geeignet sind. Außerdem wird diese Analyse zeigen, wie der Umfang der Stichproben das Ergebnis der Adaption beeinflusst. Im Rahmen dieser Untersuchung wird der Parameter für die Anzahl der auszutauschenden Trainingsbeispiele unter Berücksichtigung der Rechenzeit auf $\rho = 2000$ gesetzt. Durch die gewählte Parametereinstellung liegt die Anzahl der Iterationen während der DA zwischen 30 und 50 Iterationen.

Transferierbarkeit zwischen Kacheln der jeweiligen Testgebiete. Ergebnisse der Untersuchung zur Transferierbarkeit zwischen den Kacheln aus den unterschiedlichen Testgebieten sind in den Tabellen 6.28 und 6.29 präsentiert. Außerdem können die allgemeinen Genauigkeitswerte in diesem Fall den Ergebnissen für den POOL5 Datensatz aus der Tabelle 6.20 entnommen werden. Die Tabellen 6.28 und 6.29 zeigen hier gemittelte Ergebnisse ΔOA_{DA} und ΔOA_{TD} sowie ΔOA_{DA}^+ und ΔOA_{TD}^+ nur für positiven Transfer je nach Testgebiet in der Quell- bzw. Zieldomäne. Dabei kann ΔOA_{DA} je nach Vorzeichen als Gewinn bzw. Verlust in der Genauigkeit in Folge der Anwendung der DA gegenüber einer direkten Anwendung des an der Quelldomäne angelegten Klassifikators auf die Zieldaten anzeigen. Außerdem zeigt Tabelle 6.30 den zugehörigen Anteil an positivem Transfer für die jeweilige Konstellation. Es ist leicht zu erkennen, dass der Transfer nicht symmetrisch ist: Während es beim Transfer von *Buxtehude* auf *Vaihingen* durchschnittlich pro Test -1.1% (ΔOA_{DA}) verloren geht, fällt der Transfer von *Vaihingen* auf *Buxtehude* mit 0.2% pro Test positiv aus. Damit wird hier die Beobachtung aus [Eaton et al., 2008] nachgewiesen, nach der die Symmetrie der Wissensübertragung in realen Anwendung nicht immer gegeben ist. Der höchste Gewinn in der Genauigkeit ΔOA_{DA} von 4.2% wird bei der Adaption von *Hannover* auf *Nienburg* erreicht. Der Verlust in ΔOA_{TD} weist hier jedoch den zweitgrößten Wert von 24.9% auf. Dieser Wert deutet auf eine große Diskrepanz zwischen den beiden Domänen hin. Eine der besten Wertekombination aus ΔOA_{DA} und ΔOA_{TD} zeigt die Adaption

Tabelle 6.28: Transferierbarkeit zwischen Kacheln aus unterschiedlichen Testgebieten. Die Tabellen zeigen gemittelte Ergebnisse der DA für ΔOA_{DA} (links) und ΔOA_{TD} (rechts) aus dem POOL5 Datensatz aufgeteilt je nach Testgebiet in der Quell- bzw. Zieldomäne. Testgebiete: *Vaihingen* (Vai), *Potsdam* (Pot), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

ΔOA_{DA} [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	-0.7	-4.7	0.2	-2.4	0.1	-1.5
	Pot	0.7	-0.4	-3.1	0.3	-1.0	-0.7
	Bux	-1.1	-5.6	-0.7	-3.5	1.2	-1.9
	Han	1.8	1.7	-1.9	-1.3	4.2	0.9
	Nie	0.7	-2.2	-1.2	-3.5	0.2	-1.2
	MW	0.3	-2.2	-1.3	-2.1	0.9	

ΔOA_{TD} [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	4.7	17.1	16.7	21.7	15.6	15.2
	Pot	8.9	6.5	22.0	16.1	18.0	14.3
	Bux	12.1	14.9	3.7	20.3	9.6	12.1
	Han	16.9	17.4	27.2	6.9	24.9	18.6
	Nie	13.3	13.9	5.6	23.3	1.1	11.4
	MW	11.2	14.0	15.0	17.7	13.8	

Tabelle 6.29: Transferierbarkeit zwischen Kacheln aus unterschiedlichen Testgebieten, die in einem positiven Transfer nach der DA resultieren. Die Tabellen zeigen gemittelte Ergebnisse der DA für ΔOA_{DA}^+ (links) und ΔOA_{TD}^+ (rechts) aus dem POOL5 Datensatz aufgeteilt je nach Testgebiet in der Quell- bzw. Zieldomäne. Ergebnisse der Tests, die zu einem NT führen, wurden hier aussortiert. Testgebiete: *Vaihingen* (Vai), *Potsdam* (Pot), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

ΔOA_{DA}^+ [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	1.0	3.6	5.0	1.8	2.8	2.8
	Pot	3.0	1.2	2.4	4.4	2.2	2.6
	Bux	2.0	1.4	0.4	1.6	2.0	1.5
	Han	3.6	6.1	5.5	1.6	7.1	4.8
	Nie	2.7	1.4	0.9	0.8	0.4	1.2
	MW	2.5	2.7	2.8	2.0	2.9	

ΔOA_{TD}^+ [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	2.9	13.0	12.2	18.3	13.0	11.9
	Pot	6.9	4.4	19.4	13.4	16.7	12.2
	Bux	9.8	9.5	1.5	17.5	8.3	9.3
	Han	16.2	17.3	24.0	1.7	26.8	17.2
	Nie	10.7	10.6	4.5	15.8	0.9	8.5
	MW	9.3	11.0	12.3	13.3	13.1	

von *Potsdam* auf *Vaihingen*, deren Kacheln die gleiche Bodenpixelgröße GSD haben. Dabei liegt der Wert von ΔOA_{DA} bei 0.7% und von ΔOA_{TD} bei 8.9%. Unter den Testgebieten mit einer unterschiedlichen GSD weist die Adaption von *Nienburg* auf *Vaihingen* relativ gute Werte für ΔOA_{DA} und ΔOA_{TD} von 0.7% bzw. 13.3%. Im Allgemeinen fällt der Wert von ΔOA_{TD} in den Tests, in denen Quell- und Zieldaten unterschiedliche Bodenpixelgröße haben, größer aus. Dies deutet auf eine steigende Unähnlichkeit solcher Domänen hin, was Probleme bei der Adaption verursacht. Mit Hilfe der Mittelwerte aus der Tabelle 6.29 kann ein optimaler Ausgangstestgebiet für eine gelungene Adaption bestimmt werden. Betrachtet man allein die Verbesserung der Genauigkeit nach der DA, also den Wert von ΔOA_{DA}^+ , so bringen die Kacheln des Testgebiets *Hannover* mit 4.8% unter den restlichen Testgebieten den größten Gewinn. Außerdem zeigen diese Kacheln auch den besten Anteil an positivem Transfer von 61% (siehe Tabelle 6.30). Möchte man dagegen am wenigsten Genauigkeit gegenüber einem anhand von gelabelten Trainingsdaten an der Zieldomäne angelernten Klassifikator verlieren (ΔOA_{TD}^+ möglichst klein), so sind die Kacheln des Testgebietes *Nienburg* in der Quelldomäne gut dafür geeignet. Der Wert von ΔOA_{TD}^+ liegt dabei bei 8.5%. Als Zieldomäne werden für die Kacheln vom Testgebiet *Nienburg* der größte Gewinn ΔOA_{DA}^+ von 2.9% sowie mit 63% am meisten positiver Transfer erreicht. Der beste Mittelwert für ΔOA_{TD}^+ von 9.3% resultiert für die Kacheln des Testgebiets *Hannover* in der Zieldomäne.

Tabelle 6.30: Anteil an positivem Transfer unter den DA Ergebnissen für den POOL5 Datensatz beim Transfer zwischen den verschiedenen Testgebieten. Testgebiete: *Vaihingen* (Vai), *Potsdam* (Pot), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

Anteil DA^+ [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	43	20	71	20	56	42
	Pot	60	56	44	51	41	50
	Bux	32	12	44	24	84	39
	Han	74	60	48	56	68	61
	Nie	63	36	36	8	68	42
	MW	55	37	49	32	63	

Transferierbarkeit zwischen den Testgebieten ohne Kachelung. In dem zweiten Teil der Untersuchung in diesem Abschnitt wird zwischen den gesamten Testgebieten transferiert, d.h. die Stichproben aus allen Kacheln des jeweiligen Testgebietes aus dem POOL5 Datensatz bilden eine Quell- und eine Zieldomäne, zwischen denen dann die DA stattfindet. Die Ergebnisse sind in der Tabelle 6.31 vorgestellt. Dabei wird ein positiver Transfer in 14 aus 25 Tests erreicht. Der Mittelwert von ΔOA_{DA} über die 25 Tests liegt etwa bei 0% (-0.03%), der Median von ΔOA_{DA} liegt im positiven Bereich bei 0.3%. Dies entspricht einer Verbesserung um 1.0% für den Mittelwert bzw. um 0.6% für den Median gegenüber dem Fall aus dem vorherigen Abschnitt, in dem der Transfer zwischen einzelnen Kacheln der Testgebiete erfolgt (vgl. Tabelle 6.20). Der Mittelwert von ΔOA_{TD} über die 25 Tests liegt hier bei 10.4% (gegenüber 12.7% aus der vorherigen Untersuchung). Damit sank der Verlust der Genauigkeit ΔOA_{TD} durch die Verwendung einer umfangreicheren Stichprobenmenge deutlich. Die negativen Werte von ΔOA_{TD} in der Tabelle bedeuten, dass die Klassifikationsgenauigkeit OA_{DA} nach der DA gegenüber der Genauigkeit in der Variante V_{TT} verbessert werden konnte. Dies ist hier immer dann der Fall, wenn die Quell- und Zieldaten gleich sind. Eine generell optimale Quelle für die Adaption wäre auch hier das Testgebiet *Hannover*, wenn der Gewinn in ΔOA_{DA} als Kriterium verwendet wird. Setzt man einen möglichst kleinen Verlust in ΔOA_{TD} als Kriterium fest, so soll das Testgebiet *Nienburg* ausgewählt werden.

Die Werte von ΔOA_{DA} aus der Tabelle 6.31 haben sich hier durch die Verwendung einer umfangreicheren Stichprobenmenge im Vergleich zu den Werten aus der Tabelle 6.28 fast überall verbessert. Dabei fällt auf, dass ein großer NT beim Transfer zwischen den gesamten Testgebieten ausschließlich mit dem Testgebiet *Potsdam* in der Quell- und Zieldomäne erzielt wird. Es liegt die Vermutung nahe, dass die Daten von *Potsdam* sich zu stark von den Daten der anderen Testgebiete unterscheiden. Die Diskrepanzen können vor allem in den beiden Vegetationsklassen *Baum* und *NiedrigeVegetation* ihre Ursache haben, denn die Bilder vom *Potsdam* als einzige im Herbst aufgenommen wurden. Schließt man das Testgebiet *Potsdam* von dem Experiment aus (siehe Tabelle 6.32), so erreicht man einen positiven Transfer von $\Delta OA_{DA} = 1.33\%$ über die Testreihe. Zusammenfassend lässt sich sagen, dass die Variabilität der Daten in den Datensätzen generell eine Verbesserung der Genauigkeit bewirkt und zu einem positiven Transfer verhilft. Dabei sollen die Daten gewisse Ähnlichkeitsbedingungen erfüllen, um NT zu vermeiden.

Tabelle 6.31: Transferierbarkeit zwischen den gesamten Testgebieten ohne Kachelung. Die Tabellen zeigen gemittelte Ergebnisse der DA für ΔO_{DA} (links) und ΔO_{TD} (rechts) aus dem POOL5 Datensatz aufgeteilt je nach Testgebiet in der Quell- bzw. Zieldomäne. Testgebiete: *Vaihingen* (Vai), *Potsdam* (Pot), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

ΔO_{DA}		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
[%]							
Quelle	Vai	0.4	-8.2	6.0	-0.1	-0.5	-0.5
	Pot	0.3	1.2	-6.3	2.4	-1.5	-0.8
	Bux	-1.9	-7.2	0.3	-1.2	2.6	-1.5
	Han	-1.0	-3.2	9.8	1.1	5.6	2.5
	Nie	0.5	0.4	0.3	-0.6	0.0	0.1
	MW	-0.3	-3.4	2.0	0.3	1.3	-0.0

ΔO_{TD}		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
[%]							
Quelle	Vai	-0.4	17.8	16.6	16.2	13.9	12.8
	Pot	3.2	-1.2	16.8	8.5	11.7	7.8
	Bux	12.0	11.8	-0.3	14.2	7.5	9.0
	Han	14.5	17.8	18.5	-1.1	22.9	14.5
	Nie	10.9	7.1	2.8	16.9	-0.0	7.5
	MW	8.1	10.7	10.9	10.9	11.2	

Tabelle 6.32: Transferierbarkeit zwischen den gesamten Testgebieten unter Ausschluss vom Testgebiet *Potsdam* (vgl. mit Tabelle 6.31). Die Tabellen zeigen gemittelte Ergebnisse der DA für ΔO_{DA} aufgeteilt je nach Testgebiet in der Quell- bzw. Zieldomäne. Testgebiete: *Vaihingen* (Vai), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

ΔO_{DA}		Ziel				
		Vai	Bux	Han	Nie	MW
[%]						
	Vai	0.4	6.0	-0.1	-0.5	1.5
	Bux	-1.9	0.3	-1.2	2.6	-0.1
	Han	-1.0	9.8	1.1	5.6	3.9
	Nie	0.5	0.3	-0.6	0.0	0.1
	MW	-0.5	4.1	-0.2	1.9	+1.3

6.3.6 Untersuchung zur Einbeziehung von lokalem Kontext

In diesem Abschnitt findet eine Voruntersuchung zur Einbeziehung von Kontext im Rahmen der DA statt. Der Schwerpunkt der Untersuchung liegt auf der Analyse der Auswirkung der Einbeziehung von Kontext auf die Qualität der Adaption. Die Einbeziehung von Kontext erfolgt daher auf eine vereinfachte Weise, indem jede einzelne Stichprobe nicht nur durch ihre eigene Merkmale sondern zusätzlich durch die Merkmale der Stichproben in der unmittelbaren Nachbarschaft der Größe 3×3 um sie herum ähnlich zu [Wolf und Bileschi, 2006] beschrieben wird. Dadurch vergrößert sich der ursprüngliche Merkmalsvektor um den Faktor 9 auf insgesamt 90 Merkmale pro Stichprobe. Mit der verwendeten polynomialen Erweiterung würde die Dimension des Merkmalsraumes auf über 4000 expandieren. Aus rechentechnischen Gründen wird hier daher auf die Erweiterung des Merkmalsraumes verzichtet: Es sind somit nur lineare Entscheidungsgrenzen möglich. Die Grundlage zur Untersuchung bildet der POOL5 Datensatz (Tabelle 6.19). Die Ergebnisse dieser Untersuchung werden mit den entsprechenden Ergebnissen für den POOL5 Datensatz aus den vorherigen Kapiteln verglichen.

Nach der Einbeziehung von lokalem Kontext wird ein positiver Transfer in 68% (1836 aus 2704 Tests) gegenüber 56% der Tests davor erreicht. Ein Vergleich der DA-Ergebnisse ohne und mit Einbeziehung vom Kontext ist in Tabelle 6.33 ersichtlich. Dabei liegt bei Verwendung vom Kontext der Wert von ΔO_{DA} bei 1.3% (Median: 1.1%) im Bereich des positiven Transfers und von

ΔOA_{TD} bei 10.8% (Median: 8.8%); dies entspricht einer durchschnittlichen Verbesserung von ca. 2% gegenüber der Variante ohne Kontext. Es ist jedoch zu beachten, dass das Setting nicht identisch war: Im Fall mit lokalem Kontext erfolgte keine polynomiale Erweiterung des Merkmalsraumes, womit nur lineare Entscheidungsgrenzen möglich sind. Solche Entscheidungsgrenzen erlauben bei überlappenden Verteilungen weniger präzise Trennung der Klassen, wodurch etwas schlechtere Ergebnisse von $F1$ und OA in den Varianten V_{TT} und V_{ST} begründbar sind. Trotzdem liegt der OA -Wert von 70.1% nach der DA (Variante V_{DA}) bei dem Fall mit Kontext leicht über dem OA -Wert von 69.9% in dem Fall ohne Kontext. Im Durchschnitt hat sich die Genauigkeit der Klassen *Baum* und *Gebäude* nach der DA am besten entwickelt: sie hat sich in dem Fall mit Kontext um 3.9% bzw. 2.5% verbessert. Weitere Ergebnisse der Untersuchung sind in Abbildung 6.40 als Perzentil-Plots dargestellt. Bei ca. 80% aller Tests ist der Wert von ΔOA_{DA} besser als -1.0% und für etwa Hälfte der Tests liegt ein Wert von mindestens 1.0% vor. Die Tabelle 6.34 zeigt gemittelte Ergebnisse ΔOA_{DA} und ΔOA_{TD} nach Einbeziehung von lokalem Kontext für unterschiedliche Testgebiete in der Quell- bzw. Zieldomäne. Außerdem zeigt die Tabelle 6.35 den zugehörigen Anteil an positivem Transfer. Vergleicht man die Mittelwerte in den Tabellen 6.28 und 6.34, so hat sich die Qualität der Adaption ΔOA_{DA} für die Kacheln der Testgebiete *Vaihingen* und *Potsdam* in der Quelldomäne am besten entwickelt (-1.5% und -0.7% ohne Kontext gegenüber 1.2% und 2.0% mit Kontext). Den kleinsten durchschnittlichen Verlust in ΔOA_{TD} konnten die Kacheln der Testgebiete *Buxtehude* und *Nienburg* als Quelldaten mit jeweils 8.5% und 9.6% verzeichnen. Der größter Anteil von 91% an positivem Transfer wurde dabei zwischen den Kacheln vom Testgebiet *Vaihingen* und *Nienburg* erreicht. Aber auch für die schwierigste Konstellation, in der die Adaption ausgehend von den Kacheln des Testgebietes *Nienburg* auf die Kacheln des Testgebietes *Hannover* stattfindet, wurde ein positiver Transfer in 36% der Tests (gegenüber 8% im Fall ohne Kontext) erreicht. Ein exemplarisches Ergebnis der DA mit Einbeziehung vom Kontext ist in Abbildung 6.41 vorgestellt. Dabei fand die Adaption zwischen zwei Gebieten mit unterschiedlicher GSD statt. Als Quelldomäne dient die Kachel 07 aus dem Testgebiet *Vaihingen* und als Zieldomäne die Kachel 113 aus dem Testgebiet *Buxtehunde*. Es wird dabei ein positiver Transfer mit ΔOA_{DA} von 7.2% erreicht. Der Verlust der Genauigkeit aufgrund der fehlenden Labels in der Zieldomäne ΔOA_{TD} beträgt 5.1% . Zusammenfassend lässt sich der Rückschluss ziehen, dass die Verwendung von Kontext das Ergebnis der Adaption verbessern kann.

Tabelle 6.33: Vergleich der DA-Ergebnisse *ohne* und *mit* Einbeziehung von lokalem Kontext auf dem POOL5 Datensatz. In dem Fall ohne Kontext wurde eine polynomiale Erweiterung des Merkmalsraumes von Grad 2 verwendet, während im Fall mit Kontext keine Erweiterung eingesetzt wurde. Klassen: *Versiegelte Fläche* (Vers.), *Gebäude* (Geb.), *Niedrige Vegetation* (N.Veg.), *Baum* (Baum), *Sonstiges* (Sons.).

		F1 [%]					OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
		Vers.	Geb.	N.Veg.	Baum	Sons.			
ohne	V_{TT}	83.8	90.8	73.4	73.2	20.7	82.6	-1.0	12.7
	V_{ST}	73.6	84.4	56.5	58.2	2.8	71.0		
	V_{DA}	72.8	85.0	55.1	60.6	3.0	69.9		
mit	V_{TT}	82.9	89.3	71.5	67.8	18.7	80.9	1.3	10.8
	V_{ST}	73.2	82.1	54.5	53.7	2.5	68.8		
	V_{DA}	74.1	84.6	56.1	57.6	2.6	70.1		

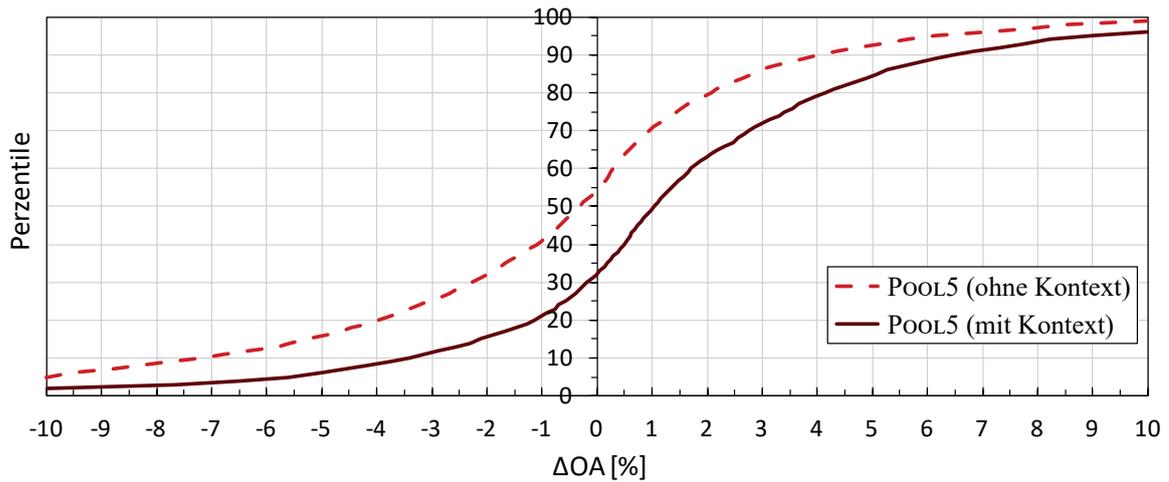


Abbildung 6.40: Ergebnisse der Untersuchung zur Einbeziehung von lokalem Kontext. Die Abbildung zeigt Perzentil-Plots der DA Ergebnisse als Funktion von $\Delta O A_{DA}$ auf dem POOL5 Datensatz für die ursprüngliche Variante ohne Einbeziehung von Kontext und für die Variante mit Einbeziehung von Kontext.

Tabelle 6.34: Ergebnisse der Untersuchung zur Einbeziehung von lokalem Kontext. Die Tabellen zeigen gemittelte Ergebnisse der DA zwischen den Kacheln der jeweiligen Testgebiete als $\Delta O A_{DA}$ (links) und als $\Delta O A_{TD}$ (rechts) aus dem POOL5 Datensatz nach Einbeziehung von Kontext aufgeteilt je nach Testgebiet in der Quell- bzw. Zieldomäne. Testgebiete: *Vaihingen* (Vai), *Potsdam* (Pot), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

$\Delta O A_{DA}$ [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	0.4	-0.2	4.0	-1.7	3.4	1.2
	Pot	3.5	0.8	2.0	1.3	2.4	2.0
	Bux	0.3	-1.3	0.6	-2.9	1.7	-0.3
	Han	5.1	3.7	4.9	-2.0	5.3	3.4
	Nie	0.6	0.8	0.0	-1.1	0.6	0.2
	MW	2.0	0.8	2.3	-1.3	2.7	

$\Delta O A_{TD}$ [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	3.7	12.9	14.1	20.3	14.2	13.0
	Pot	8.2	6.0	22.3	16.0	20.3	14.6
	Bux	8.8	7.9	2.5	15.7	7.6	8.5
	Han	13.7	14.2	19.4	6.6	24.4	15.7
	Nie	12.5	10.0	4.7	19.9	0.9	9.6
	MW	9.4	10.2	12.6	15.7	13.5	

Tabelle 6.35: Anteil an positivem Transfer nach der DA für den POOL5 Datensatz beim Transfer zwischen den jeweiligen Testgebieten nach Einbeziehung von lokalem Kontext (vgl. mit Tabelle 6.30). Testgebiete: *Vaihingen* (Vai), *Potsdam* (Pot), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

Anteil DA^+ [%]		Ziel					
		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	69	51	83	27	91	64
	Pot	86	72	71	57	77	73
	Bux	56	43	84	24	84	58
	Han	88	71	84	60	88	78
	Nie	66	63	64	36	84	63
	MW	73	60	77	41	85	

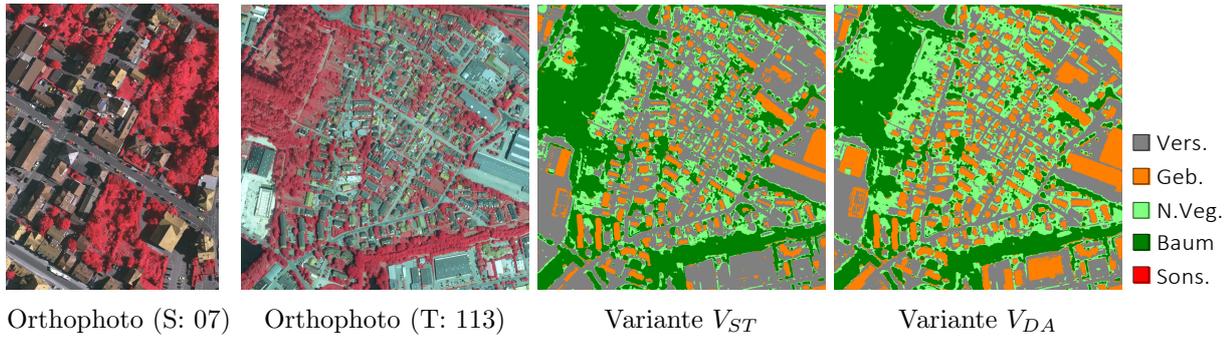


Abbildung 6.41: Exemplarisches Ergebnis der DA ausgehend von der Kachel 07 (Quelldomäne) aus dem Testgebiet *Vaihingen* auf die Kachel 113 (Zieldomäne) aus dem Testgebiet *Buxtehude*. Exakte Werte zur Beurteilung der Qualität der Adaption für das Beispiel sind in Tabelle 6.36 zusammengefasst.

Tabelle 6.36: Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeiten für die Varianten V_{TT} , V_{ST} und V_{DA} sowie Qualitätsmaße der Adaption für Beispiel aus Abbildung 6.41. Dabei wird nach der DA ein positiver Transfer mit ΔOA_{DA} von 7.2% erreicht.

	$F1$ [%]					OA [%]	ΔOA_{DA} [%]	ΔOA_{TD} [%]
	Vers.	Geb.	N.Veg.	Baum	Sons.			
V_{TT}	79.9	84.7	72.9	87.1	63.7	80.9		
V_{ST}	65.8	56.3	63.6	85.1	0.0	68.6	7.2	5.1
V_{DA}	73.0	75.7	69.9	86.4	0.0	75.8		

6.3.7 Diskussion

Die Experimente in diesem Kapitel zeigen die Leistungsfähigkeit des entwickelten Ansatzes zur DA an unterschiedlichen Evaluierungsdatensätzen aus 5 Testgebieten: *Vaihingen*, *Potsdam*, *Buxtehude*, *Hannover* und *Nienburg*. Der Hintergrund dieser Untersuchung lag in der Überprüfung der in der Einleitung aufgestellten Forschungsfragen, dass ein Transfer zwischen den unterschiedlichen Gebieten unter der Anwendung von DA möglich ist und dass der Genauigkeitsverlust gegenüber einem erneut anhand von gelabelten Trainingsdaten angelernten Klassifikator dank dem entwickelten DA Ansatz relativ klein gehalten werden kann. Es wurde auf Basis der Datensätze *Vaihingen* und *Potsdam* gezeigt, dass ein positiver Transfer ($\Delta OA_{DA} \geq 0\%$) zwischen den Bilddaten eines Testgebietes in 42% bzw. 56% der Tests erreicht wird. Betrachtet man ausschließlich die Ergebnisse der Tests für den 3CITYDS, POOL2 und POOL5 Datensatz, in denen die DA zwischen den Kacheln aus unterschiedlichen Testgebieten stattfindet, so wird ein positiver Transfer in ca. 45%, 40% und 44% der Tests für den jeweiligen Datensatz erreicht. Außerdem resultiert für den POOL5 Datensatz ein positiver Transfer in rund 47% der Tests, in denen die Bildkacheln der Quell- und Zieldomäne den Testgebieten mit unterschiedlicher GSD gehören. Damit ist mit dem entwickelten Ansatz ein positiver Transfer zwischen verschiedenen Gebieten möglich, deren Bilddaten sich in Bezug auf die Bebauungsstruktur der Städte, sowie Aufnahmesensorik, Lichtverhältnisse, saisonale Effekte und Auflösung der Daten unterscheiden. Dennoch entsteht in rund 50% der Tests ein NT (siehe Abbildung 6.17). Dabei liegt der Verlust in ΔOA_{DA} für ca. 95% der Tests aus dem *Vaihingen* und *Potsdam* und für 85% der Tests aus dem 3CITYDS, POOL2 und POOL5 Datensatz bei weniger als 5% in OA ($\Delta OA_{DA} \geq -5\%$). Eine Verbesserung von mindestens 2% in OA ($\Delta OA_{DA} \geq 2\%$) wird nach der DA in 5%, 9%, 20%, 15% bzw. 21% der Tests aus dem *Vaihingen*, *Potsdam*, 3CITYDS, POOL2 bzw. POOL5

erreicht. Es geht im Median eine Genauigkeit ΔOA_{TD} gegenüber einem anhand von gelabelten Trainingsdaten in der Zieldomäne angelernten Klassifikator von 4.0% für *Vaihingen*, 4.7% für *Potsdam*, 10.4% für 3CITYDS, 7.1% für POOL2 und 11.2% für POOL5 verloren. Betrachtet man die Tests mit positivem Transfer separat (Tabelle 6.20), stellt man fest, dass eine durchschnittliche Verbesserung ΔOA_{DA}^+ von 1.0% bei dem *Vaihingen* bis zu 2.6% bei dem 3CITYDS und POOL5 erreicht wird. Der durchschnittliche Genauigkeitsverlust ΔOA_{TD}^+ gegenüber einem erneut anhand gelabelten Trainingsdaten angelernten Klassifikator liegt in einem Bereich von 10.5% bei dem 3CITYDS bis 2.9% bei dem *Vaihingen* Datensatz. Dabei sind die Werte des Medians meist deutlich besser (z.B. 5.7% für 3CITYDS), dies deutet auf einzelne Ausreißer in der Testreihe mit größeren ΔOA_{TD} -Werten hin. Eine Erweiterung der Menge an Trainingsdaten (siehe Abschnitt 6.3.5) wirkt sich bei den Tests auf dem POOL5 Datensatz positiv auf die Qualität der Adaption und führt zu einer Verbesserung der DA-Ergebnisse. Dabei verbessert sich der Mittelwert von ΔOA_{DA} von -1.0% um 1.0% auf 0.0% . Schließt man zusätzlich von dem Test die Daten aus, die die Ähnlichkeitsbedingung nicht erfüllen, wird ein positiver Transfer von $\Delta OA_{DA} = 1.3\%$ über die Testreihe erreicht. Damit wirkt sich die Variabilität der Daten unter Einhaltung der Ähnlichkeitsbedingung besonders positiv auf die Qualität der Adaption. Der Mittelwert von ΔOA_{TD} reduziert sich weiterhin um 2.3% auf 10.4% . Eine Einbeziehung vom Kontext (ohne Erweiterung der Trainingsdatenmenge) führt bei den Tests auf dem POOL5 Datensatz ebenso zu einer Verbesserung der DA-Ergebnisse. Der Mittelwert von ΔOA_{DA} liegt hier bei 1.3% und der Mittelwert von ΔOA_{TD} bei 10.8% . Dabei lag der Wert von ΔOA_{TD} für ca. 30% der Tests sowohl mit Erweiterung der Trainingsdatenmenge als auch bei der Einbeziehung von Kontext unter 5%. Damit konnte gezeigt werden, dass ein Transfer zwischen den unterschiedlichen Gebieten möglich ist und dass der Genauigkeitsverlust gegenüber einem erneut anhand von gelabelten Trainingsdaten angelernten Klassifikator für viele Tests relativ klein gehalten werden kann, wenn auch nicht für alle.

Eine Analyse der datenspezifischen Ergebnisse aus Kapitel 6.3.4 hat ergeben, dass eine Reihe von Faktoren für die Qualität der DA von entscheidender Bedeutung sind. Eine Gruppe solcher Faktoren ist auf die Unterschiede zwischen den Domänen zurückzuführen, die dazu führen, dass die Ähnlichkeitsbedingung der DA nicht erfüllt ist. Manche Ursachen dafür sind nur schwer vermeidbar, wie z.B. saisonale Unterschiede, während die anderen korrigiert werden können, z.B. durch Änderung des Interpretationsschlüssels in den Trainingsdaten (siehe zum Beispiel den Fall mit Weingarten in dem Testgebiet *Vaihingen* in Abschnitt 6.3.4). Ein weiterer Faktor ist eine starke Überlappung der Merkmalsausprägungen der einzelnen Klassen untereinander sowohl in Quell- als auch in der Zieldomäne. In Folge können solche Klassenverteilungen (sogar unter Einbeziehung der Labels fürs Training) mit der LR nicht gut von einander getrennt werden. Mögliche Ursachen dafür könnten wiederum die saisonale oder regionale Unterschiede, die Verwendung der unterschiedlichen Interpretationsschlüssel in der Quell- und Zieldomäne oder die Qualität der Daten selbst sein (siehe z.B. Analyse für den 3CITYDS Datensatz in Abschnitt 6.3.4). Ein Lösungsansatz wäre z.B. Verwendung zusätzlicher (zu den bereits vorhandenen) Merkmale, die diese Überlappungen besser auflösen können. Weiterhin stellen stark unterrepräsentierte Klassen (wie z.B. Klasse *Sonstiges*) bedingt durch den verwendeten Ansatz zur DA mit der LR als Basisklassifikator ein Problem dar. Solche Klassen in der Zieldomäne

können z.B. aufgrund der Unterschiede zwischen Quell- und Zieldomäne einfacher einer falschen Klasse während der DA zugeteilt werden, da die Semi-Labels auf Basis einer lokalen Analyse (von K -NN und aus dem aktuellen Zustand des Klassifikators) zugewiesen werden (siehe Analyse für den POOL2 Datensatz in Abschnitt 6.3.4). Hier könnten zusätzliche Informationen zu der jeweiligen Klassenverteilung, z.B. aus einem Clusterverfahren, eine Abhilfe schaffen. Schließlich war die Verwendung unterschiedlicher Klassenstrukturen ein für die Qualität der DA limitierender Faktor. Das Problem hat sich in den Tests z.B. für die Klasse *Sonstiges* ergeben. In manchen Tests waren die Stichproben dieser Klasse unter den Trainingsdaten entweder aus der Quelle oder dem Ziel nicht vorhanden. Der Grund ist, dass die Klasse *Sonstiges* nicht in allen Kacheln vorkommt oder sehr stark unterrepräsentiert ist. Eine mögliche Lösung für das Problem ist die Zuweisung dieser Klasse zu einer übergeordneten Klasse mit ähnlichen Merkmalscharakteristika, wodurch sich die Anzahl der Klassen hier auf vier reduzieren würde. Ist diese Klasse jedoch für eine bestimmte Aufgabe relevant, müssen hier die Methoden des TL angewandt werden, die mit unterschiedlicher Anzahl der Klassen in der Quell- und Zieldomäne umgehen können [Tuia et al., 2011a; Bahirat et al., 2012]. Es könnte außerdem in den Experimenten die Beobachtung aus [Eaton et al., 2008] bestätigt werden, dass die Symmetrie der Wissensübertragung in realen Anwendung nicht immer eingehalten werden kann. Dabei führt das Vertauschen der Domänen teilweise zu sehr unterschiedlichen Genauigkeiten nach der DA. All dies verdeutlicht die Notwendigkeit der geeigneten Strategien zur Prädiktion und Vermeidung von NT.

6.4 Klassifikationsergebnisse nach Prädiktion von negativem Transfer

6.4.1 Zielsetzung

Die Experimente in diesem Kapitel haben zum Ziel, die entwickelte Strategie zur Prädiktion von NT unter realen Bedingungen zu untersuchen. Der Hintergrund dieser Untersuchung liegt in der Überprüfung der in der Einleitung aufgestellten Forschungsfrage, dass die Fälle von NT vorhergesagt und dadurch vermieden werden können, um die Qualität der Adaption zu verbessern.

6.4.2 Durchführung der Experimente

Vorgehensweise bei der Evaluierung. Zum Zweck der Untersuchung der Strategie zur Prädiktion von NT werden alle fünf Testgebiete (*Vaihingen*, *Potsdam*, *Buxtehude*, *Hannover* und *Nienburg*) verwendet, aus denen verschiedene Datensätze gebildet werden. Folglich weisen die gebildeten Datensätze Unterschiede in Bezug auf die Aufnahmesensorik, Lichtverhältnisse, saisonale Effekte und Bodenpixelgröße auf, die je nach Datensatz unterschiedlich stark ausgeprägt sind. Bei der Durchführung der Experimente wird die gesamte Testreihe des jeweiligen Datensatzes getestet und ausgewertet. Die Klassenlabels für die Zieldomäne werden nur zum Zweck

der Evaluierung verwendet. Die Vergleichswerte für die Genauigkeit vor der Prädiktion von NT werden den Experimenten aus dem vorherigen Kapitel und insbesondere aus Tabelle 6.20 entnommen. Die Prädiktion von NT mit dem Schwellwert $\tau_{MMD_m}^{Pred} = 0.235$, der im Kapitel 6.2.3 ermittelt wurde, erfolgt gemäß Gleichung 6.1.

Datensätze. Die Evaluierung der DA erfolgt auf den fünf Datensätzen: $\mathfrak{D}_{\mathfrak{U}_4}^{Vai}$, $\mathfrak{D}_{\mathfrak{U}_4}^{Pot}$, $\mathfrak{D}_{\mathfrak{U}_4}^{3CITYDS}$, $\mathfrak{D}_{\mathfrak{U}_4}^{POOL2}$, $\mathfrak{D}_{\mathfrak{U}_4}^{POOL5}$. Diese sind identisch mit den jeweiligen Datensätzen \mathfrak{U}_3 aus dem vorherigen Abschnitt (siehe Tabelle 6.19).

In jedem Experiment findet die Untersuchung anhand einer Testreihe statt. Bei jedem Test der Testreihe wird eine Kachel aus dem verwendeten Datensatz als Quelldomäne und eine Kachel als Zieldomäne gewählt. Alle möglichen Kombinationen von Kacheln bilden eine Testreihe, wobei die Verwendung derselben Kachel als Quell- und Zieldomäne möglich ist.

Quelle und Ziel. Im Kontext der DA wird hier unter Quelle S die Kachel gemeint, an deren Daten der initiale Klassifikator trainiert wird. Als Ziel T wird die Kachel bezeichnet, die zum Testen der DA zum Einsatz kommt. Im Rahmen dieser Untersuchung stehen Labels nur für die Daten aus der Quelldomäne zur Verfügung. Die Klassenlabels für die Daten aus der Zieldomäne werden nur zur Auswertung der Genauigkeiten verwendet.

Auswertung. Die Analyse der Korrelation zwischen den Werten von ΔOA_{DA} bzw. von ΔOA_{TD} und der MMD_m -Metrik erfolgt mittels der linearen Regression. Dabei wird zur Bewertung der Ergebnisse das Bestimmtheitsmaß R^2 und der zugehörige empirische Korrelationskoeffizient r eingesetzt. Der Schwerpunkt bei der Auswertung der Ergebnisse nach der Prädiktion von NT im Rahmen dieser Untersuchung liegt auf dem Vergleich der Gesamtgenauigkeit OA_{DA} sowie der Genauigkeitsänderungen ΔOA_{DA} und ΔOA_{TD} vor und nach der Prädiktion. Außerdem werden klassenspezifische Qualitätsmaße Korrektheit, Vollständigkeit und $F1$ -Maß zur Auswertung der Genauigkeiten einzelner Klassen verwendet.

6.4.3 Ergebnisse

Analyse der Korrelation mithilfe der linearen Regression. Zunächst werden die Ergebnisse der linearen Regression für ΔOA_{DA} und MMD_m analysiert (siehe Abbildung 6.42). Die Evaluierung der Regression bestätigt die Beobachtung aus dem Kapitel 6.2, dass die Korrelation zwischen ΔOA_{DA} und der Distanzmetrik auf Basis der modifizierten MMD-Matrix, die unter den untersuchten Ansätzen zur Prädiktion von NT die besten Ergebnisse gezeigt hat, keine zufriedenstellende Werte liefert. Dabei variiert der Bestimmtheitsmaß im Bereich von $R^2 = 0.028$ (entspricht dem empirischen Korrelationswert von $|r| = 16.7\%$) für den POOL5 Datensatz bis $R^2 = 0.182$ ($|r| = 42.7\%$) für den *Vaihingen* Datensatz. Die Ergebnisse der Analyse der linearen Regression für ΔOA_{TD} und MMD_m sind in Abbildung 6.43 präsentiert. Hier liegen die Werte des Bestimmtheitsmaßes jeweils bei $R^2 = 0.376$ ($|r| = 61.3\%$), $R^2 = 0.116$ ($|r| = 34.1\%$), $R^2 = 0.352$ ($|r| = 59.3\%$), $R^2 = 0.212$ ($|r| = 46.0\%$) und $R^2 = 0.231$ ($|r| = 48.1\%$) für den *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* bzw. den *POOL5* Datensatz. Das heißt, dass die Distanzmetrik

MMD_m mit dem Genauigkeitsmaß ΔOA_{TD} , welches einen Verlust in der Gesamtgenauigkeit nach DA aufgrund den fehlenden Trainingsdaten in der Zieldomäne repräsentiert, besser korreliert. Damit wäre die MMD_m -Metrik zur Prädiktion des Genauigkeitsmaßes ΔOA_{TD} besser als zur Prädiktion von ΔOA_{DA} , über welches der NT definiert ist, geeignet. Außerdem könnte man die Ergebnisse aus Abbildung 6.43 als Hinweis dafür sehen, dass bei einem größeren Wert der MMD_m -Metrik für eine Quell- und Zieldomäne keine Adaption stattfinden soll, weil ein hoher Verlust in ΔOA_{TD} unabhängig vom Ausgang der DA mit höher Wahrscheinlichkeit zu erwarten ist. Stattdessen soll man in diesem Fall auf bessere Alternativen zugreifen, etwa indem gelabelte Trainingsdaten für die Zieldomäne produziert werden.

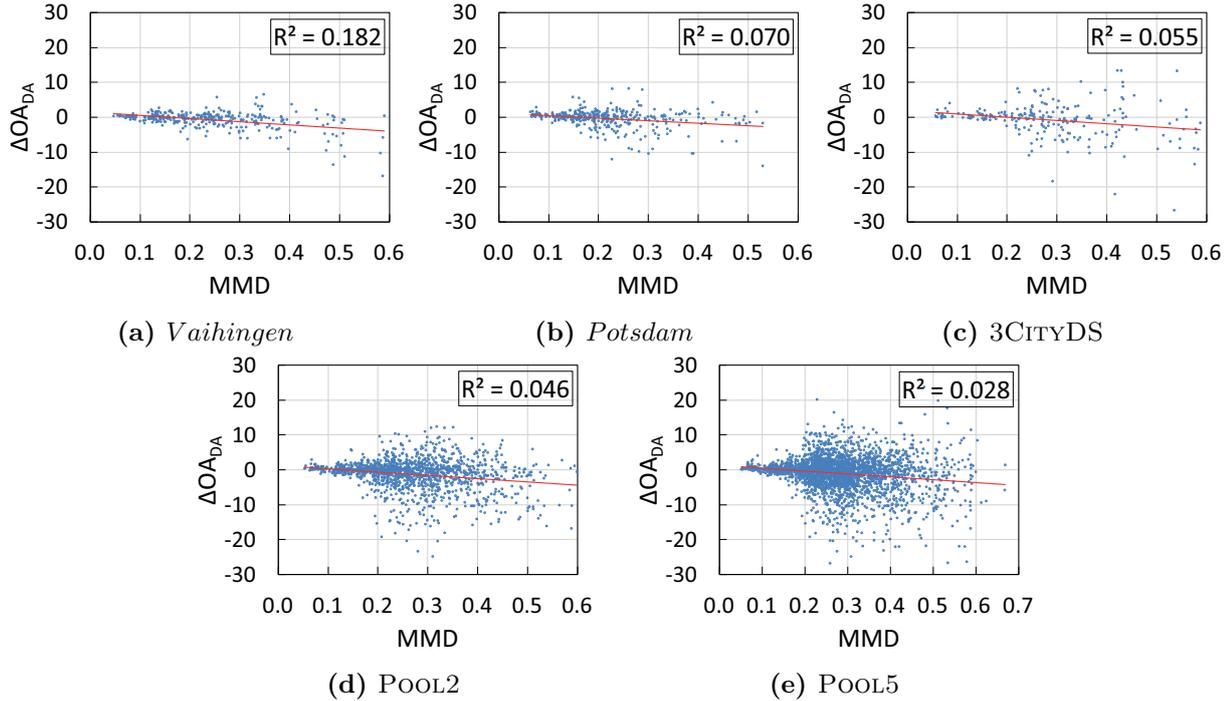


Abbildung 6.42: Ergebnisse der Regressionsanalyse für ΔOA_{DA} und MMD_m auf den Datensätzen $\mathcal{D}_{\mathcal{U}_4}^{Vai}$ (a), $\mathcal{D}_{\mathcal{U}_4}^{Pot}$ (b), $\mathcal{D}_{\mathcal{U}_4}^{3CITYDS}$ (c), $\mathcal{D}_{\mathcal{U}_4}^{POOL2}$ (d) und $\mathcal{D}_{\mathcal{U}_4}^{POOL5}$ (e).

Analyse der Prädiktion von negativem Transfer. Als Nächstes werden Ergebnisse nach der Prädiktion von NT näher betrachtet. Die Abbildung 6.44 zeigt ein Perzentil-Plot über ΔOA_{DA} pro Datensatz mit je 3 Fällen: Originalverteilung der Ergebnisse ohne Prädiktion von NT, Verteilung der Ergebnisse nach Prädiktion mit einem optimalen Schwellwert $\tau_{MMD_m}^{ROC}$, der mit Hilfe der ROC und unter Einbeziehung der Labels in der Zieldomäne ermittelt wurde, und Verteilung nach Prädiktion von NT mit dem ausgewählten Schwellwert $\tau_{MMD_m}^{Pred} = 0.235$.

Nach der Prädiktion wird gemäß der Definition aus Gleichung 5.7 ein positiver Transfer in 72%, 76%, 89%, 82% bzw. 86% der Tests für den jeweiligen Datensatz *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* bzw. *POOL5* (gegenüber 42%, 56%, 49%, 45% bzw. 46% in den Tests davor) erzielt. Es wird jedoch auch ein relativ großer Teil von positivem Transfer fälschlicherweise als NT klassifiziert. So lässt sich aus dem jeweiligen Perzentil-Plot ablesen, dass NT auf Grundlage des Schwellwertes $\tau_{MMD_m}^{Pred}$ jeweils für ca. 46% (145 aus 324), 36% (126 aus 361), 66% (147 aus 225), 60% (812 aus 1369) und 68% (1849 aus 2704) der Tests aus dem Datensatz *Vaihingen*,

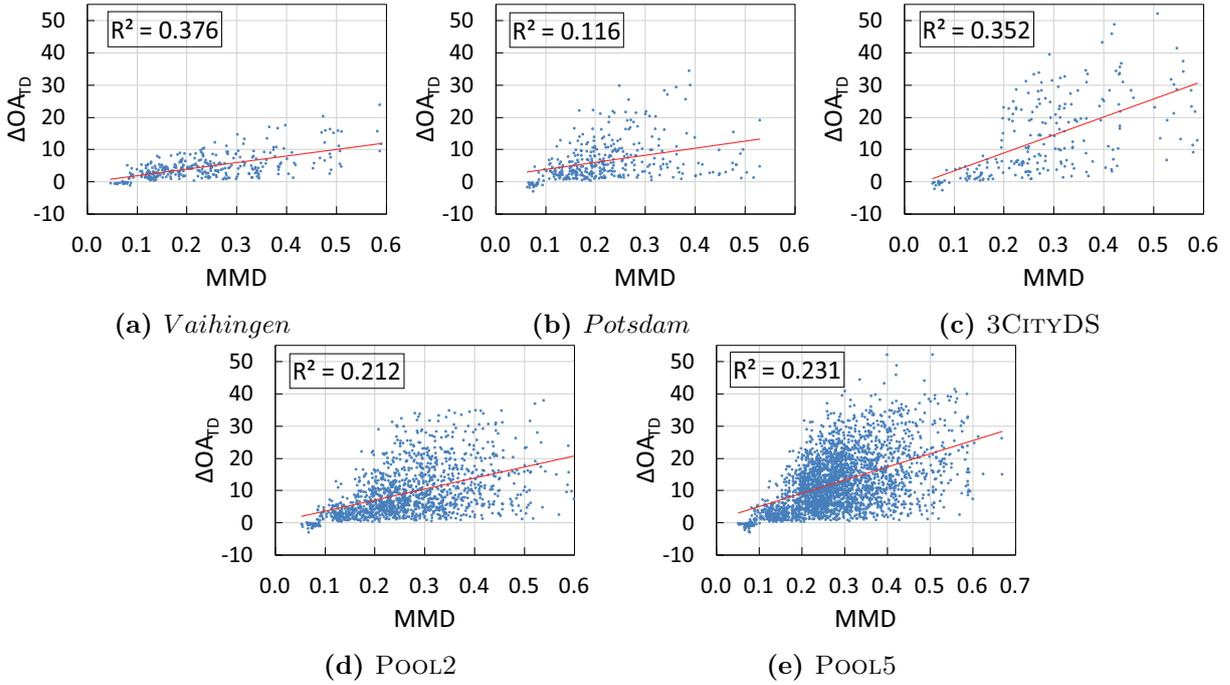


Abbildung 6.43: Ergebnisse der linearen Regressionsanalyse für ΔO_{ATD} und MMD_m auf den Datensätzen $\mathfrak{D}_{\mathcal{M}_4}^{Vai}$ (a), $\mathfrak{D}_{\mathcal{M}_4}^{Pot}$ (b), $\mathfrak{D}_{\mathcal{M}_4}^{3CITYDS}$ (c), $\mathfrak{D}_{\mathcal{M}_4}^{POOL2}$ (d) und $\mathfrak{D}_{\mathcal{M}_4}^{POOL5}$ (e).

Potsdam, *3CITYDS*, *POOL2* bzw. *POOL5* vorhergesagt wurde. Dabei hätten jeweils etwa 65%, 56%, 61%, 62% bzw. 59% dieser Tests tatsächlich zu einem NT geführt. Diese Zahlen entsprechen der Korrektheit der Prädiktion von NT auf dem jeweiligen Datensatz. Die exakten Qualitätsmaße der Prädiktion von NT sind in Tabelle 6.37 dargestellt.

Tabelle 6.37: Qualitätsmaße *Vollständigkeit* (Comp), *Korrektheit* (Corr) und *F1-Maß* (F1) der Prädiktion von NT für die Datensätze $\mathfrak{D}_{\mathcal{M}_4}^{Vai}$, $\mathfrak{D}_{\mathcal{M}_4}^{Pot}$, $\mathfrak{D}_{\mathcal{M}_4}^{3CITYDS}$, $\mathfrak{D}_{\mathcal{M}_4}^{POOL2}$ und $\mathfrak{D}_{\mathcal{M}_4}^{POOL5}$. Abkürzung MW bezeichnet den Mittelwert über die Werte in der jeweiligen Spalte.

	Comp [%]	Corr [%]	F1 [%]	
Datensatz	$\mathfrak{D}_{\mathcal{M}_4}^{Vai}$	49.7	64.8	56.3
	$\mathfrak{D}_{\mathcal{M}_4}^{Pot}$	43.5	55.6	48.8
	$\mathfrak{D}_{\mathcal{M}_4}^{3CITYDS}$	76.7	60.5	67.7
	$\mathfrak{D}_{\mathcal{M}_4}^{POOL2}$	66.3	62.3	64.3
	$\mathfrak{D}_{\mathcal{M}_4}^{POOL5}$	73.8	58.8	65.4
MW	62.0	60.4	60.5	

Der *F1*-Maß der Prädiktion von NT liegt jeweils bei 56.3%, 48.8%, 67.7%, 64.3% und 65.5% für den $\mathfrak{D}_{\mathcal{M}_4}^{Vai}$, $\mathfrak{D}_{\mathcal{M}_4}^{Pot}$, $\mathfrak{D}_{\mathcal{M}_4}^{3CITYDS}$, $\mathfrak{D}_{\mathcal{M}_4}^{POOL2}$ bzw. $\mathfrak{D}_{\mathcal{M}_4}^{POOL5}$ Datensatz. Die relativ niedrigen *F1*-Werte bestätigen nun praktisch die Schlussfolgerung aus der Analyse der Korrelation zwischen MMD_m und ΔO_{ADA} mithilfe der linearen Regression, dass auch die MMD_m -Metrik den NT nicht ausreichend gut erkennen kann. Nichtsdestotrotz ist es damit möglich, ein Teil von NT zu erkennen und das Ergebnis der Adaption über den jeweiligen Testdatensatz zu verbessern. Die exakten Genauigkeiten für den jeweiligen Datensatz sind in der Tabelle 6.38 zusammengefasst. Die Tabelle zeigt klassenspezifische Qualitätsmaße, die Genauigkeit der Adaption O_{ADA} , die Genauigkeitsänderungen ΔO_{ADA} und ΔO_{ATD} vor bzw. nach der Prädiktion von NT sowie die durch

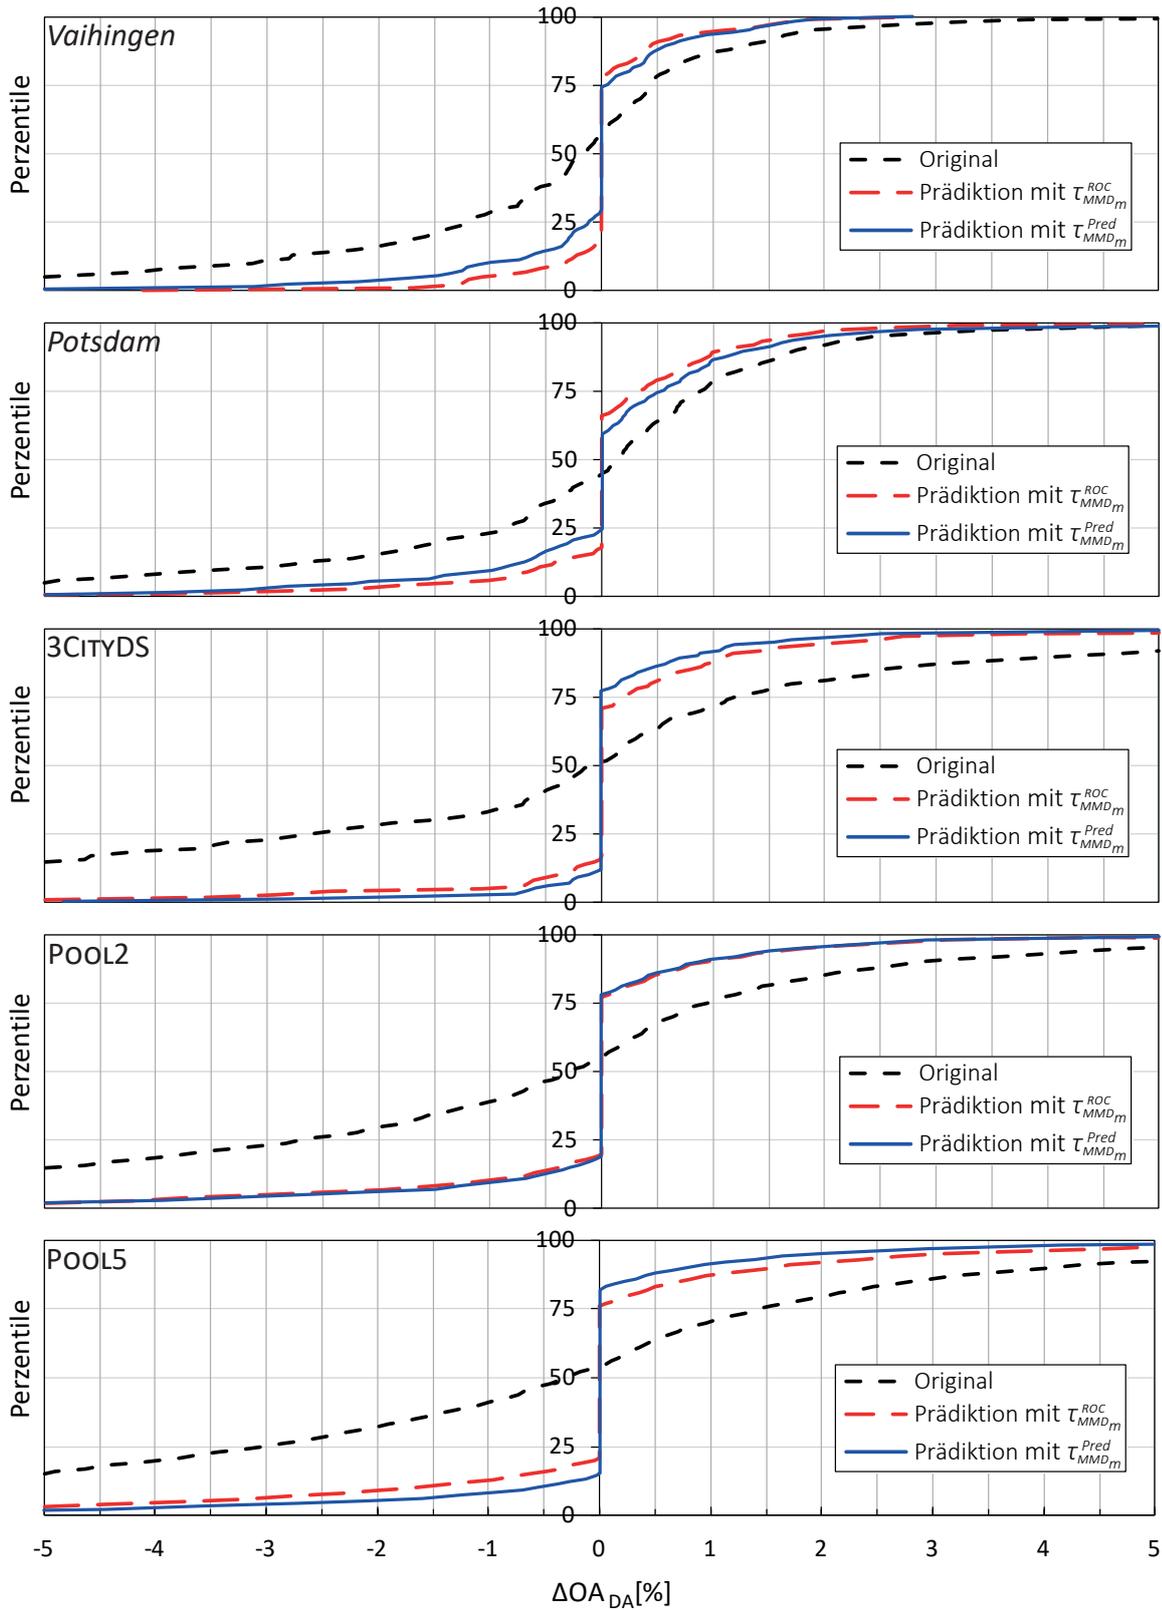


Abbildung 6.44: Perzentil-Plots als Funktion von ΔOA_{DA} für die Datensätze *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2*, *POOL5* vor und nach der Prädiktion von NT mit dem Schwellwert $\tau_{MMD_m}^{Pred}$ und $\tau_{MMD_m}^{ROC}$ zum Vergleich.

Prädiktion erreichte Verbesserung in OA für den jeweiligen Datensatz. Durch die Prädiktion von NT konnte im Mittel ein leicht positiver Transfer von 0.1% jeweils für den *Potsdam* und den *POOL5* Datensatz und positiver Transfer von 0.2% für den *3CITYDS* Datensatz erreicht werden (siehe ΔOA_{DA}^{NT} in der Tabelle 6.38). Bei den zwei restlichen Datensätzen ergibt sich im Mittel etwa 0.0%. Damit entsprechen diese Ergebnisse einer Verbesserung der Genauigkeit von 0.6%, 0.4%, 0.9%, 1.1% bzw. 1.0% auf dem *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* bzw. dem *POOL5* Datensatz gegenüber der Genauigkeit vor der Prädiktion. Es ist zu bemerken, dass der Wert des Medians von ΔOA_{DA}^{NT} nach der Prädiktion von NT hier immer bei 0.0% liegt (siehe Abbildung 6.44). Damit ist der Median von ΔOA_{DA}^{NT} für eine Analyse hier nicht geeignet und wird daher nicht betrachtet.

Entsprechend der oben erwähnten Verbesserung reduziert sich auch der mittlere Verlust ΔOA_{TD}^{NT} gegenüber dem Wert ohne Prädiktion ΔOA_{TD}^U (siehe Tabelle 6.38). Der neue Wert von ΔOA_{TD}^{NT} liegt bei 4.2% (Median: 3.9%), 6.1% (Median: 4.5%), 12.7% (Median: 9.3%), 8.2% (Median: 6.6%) bzw. 11.4% (Median: 10.4%) für den *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* bzw. den *POOL5* Datensatz. Der Median von ΔOA_{TD}^{NT} erlaubt den Rückschluss, dass für die Hälfte der Tests aus dem jeweiligen Datensatz *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* bzw. *POOL5* ein Verlust in der Genauigkeit von weniger als 3.9%, 4.5%, 9.3%, 6.6% bzw. 10.4% gegenüber dem an den gelabelten Zieldaten angelernten Klassifikator nach der *DA* mit der Prädiktion von NT erreicht wird. Eine separate Analyse der Fälle, für die ein positiver bzw. negativer Transfer vorhergesagt wurde, zeigt keine bemerkenswerten Ergebnisse und wird aus diesem Grund nicht detailliert vorgestellt. Es lässt sich aus dieser Analyse nur erkennen, dass der Verlust ΔOA_{TD} in den Fällen, für die ein positiver Transfer vorhergesagt wurde, deutlich kleiner (etwa um den Faktor 2) als für die Tests ist, in denen basierend auf der vorgeschlagenen Strategie ein NT erwartet wird. Allerdings war ein gutes Abschneiden von ΔOA_{TD} aufgrund der Prädiktion mittels MMD_m aus der Analyse der Korrelation mithilfe der linearen Regression im vorherigen Abschnitt zu erwarten, denn ΔOA_{TD} korreliert mit der MMD_m -Metrik wesentlich besser als ΔOA_{DA} . Die klassenspezifische Qualitätsmaße aus der Tabelle 6.38 lassen keine besondere Auffälligkeiten erkennen. Am meisten profitieren durch den Einsatz der Prädiktion die Klassen *Versiegelte Fläche* und *Niedrige Vegetation*, deren $F1$ -Maß nach der Prädiktion von NT entweder steigt oder zumindest auf dem selben Niveau bleibt; für die anderen Klassen reduziert sich das $F1$ -Maß überwiegend. Die einzige Ausnahme stellt der *3CITYDS* Datensatz, bei dem das $F1$ -Maß sich für die Klasse *Niedrige Vegetation* nach der Prädiktion um 0.9% auf 53.0% reduziert. Im Mittel steigt die Qualität der Erkennung der Klassen *Versiegelte Fläche* und *Niedrige Vegetation* um 0.6% bzw. 0.8% nach der Prädiktion von NT.

Prädiktion zwischen Kacheln unterschiedlicher Testgebiete. Die Analyse der Prädiktion von NT zwischen den Kacheln unterschiedlicher Testgebiete findet auf dem *POOL5* Datensatz statt, der alle möglichen Kombinationen der Bildkacheln aus allen Testgebieten beinhaltet. Die Ergebnisse der Analyse sind in Tabelle 6.39 präsentiert. Die Tabelle zeigt die Qualitätsmaße Vollständigkeit, Korrektheit und $F1$ -Maß der Prädiktion von NT. Die beste Korrektheit von 80.1% im Mittel über alle Testgebiete wird für Kacheln des Testgebietes *Hannover* in der Ziel-domäne erreicht. Die schlechteste Korrektheit im Mittel über alle Testgebiete liegt dabei bei

Tabelle 6.38: Ergebnisse der DA unter Berücksichtigung der Prädiktion von NT. Die Tabelle zeigt klassenspezifische Qualitätsmaße, Genauigkeitswerte OA_{DA} , ΔOA_{DA} und ΔOA_{TD} vor und nach der Prädiktion von NT sowie die durch Prädiktion erreichte Verbesserung in OA für den jeweiligen Datensatz. Die ursprünglichen Genauigkeitswerte und klassenspezifische Qualitätsmaße (ohne Prädiktion) V_{DA}^U sind der Tabelle 6.20 entnommen. Klassenspezifische Qualitätsmaße: *Vollständigkeit* (Comp), *Korrektheit* (Corr), *F1-Maß* (F1). Genauigkeitsmaße: *Gesamtgenauigkeit* (OA), Änderung der Genauigkeit aufgrund der Anwendung der DA (ΔOA_{DA}), Verlust der Genauigkeit aufgrund der fehlenden Trainingsdaten in der Zieldomäne gegenüber der DA (ΔOA_{TD}). Klassen: *Versiegelte Fläche* (Vers.), *Gebäude* (Geb.), *Niedrige Vegetation* (N.Veg.), *Baum* (Baum), *Sonstiges* (Sons.). Statistischen Kennwerte: *Median* (Med.), *Mittelwert* (MW), *Standardabweichung* (Std.).

		Ursprünglich			Nach Prädiktion von NT							
		V_{DA}^U			V_{DA}^{NT}							
		Comp [%]	Corr [%]	F1 [%]	Comp [%]	Corr [%]	F1 [%]					
Vaihingen	Vers.	80.3	82.9	80.8	82.5	81.7	81.6					
	Geb.	90.2	88.0	88.9	88.8	88.9	88.7					
	N.Veg.	67.0	65.6	64.8	67.8	66.0	65.8					
	Baum	81.5	77.8	78.9	79.6	79.9	79.0	ΔOA_{DA}^U	ΔOA_{TD}^U	ΔOA_{DA}^{NT}	ΔOA_{TD}^{NT}	
	Sons.	0.8	0.7	0.7	0.7	1.0	0.7					Verbesserung $V_{DA}^{NT} - V_{DA}^U$
	OA [%]	Med.	79.5			79.8			-0.2	4.0	-	3.9
	MW	79.2			79.9			-0.7	4.7	0.0	4.2	0.6
	Std.	4.7			4.4			2.4	3.8	0.9	2.7	-
Potsdam	Vers.	83.9	79.2	80.4	85.0	78.4	80.4					
	Geb.	91.9	90.6	90.9	90.9	91.2	90.8					
	N.Veg.	71.8	67.3	68.1	73.4	66.9	68.7					
	Baum	56.8	56.9	55.4	54.1	58.8	54.8	ΔOA_{DA}^U	ΔOA_{TD}^U	ΔOA_{DA}^{NT}	ΔOA_{TD}^{NT}	
	Sons.	7.1	16.9	7.4	6.4	18.2	7.1					Verbesserung $V_{DA}^{NT} - V_{DA}^U$
	OA [%]	Med.	76.3			76.4			0.2	4.7	-	4.5
	MW	75.2			75.6			-0.4	6.5	0.1	6.1	0.4
	Std.	7.2			6.8			2.6	6.2	1.5	5.6	-
3CrrvDS	Vers.	69.5	71.1	68.0	71.6	69.1	68.0					
	Geb.	82.6	78.0	79.7	80.8	79.4	79.2					
	N.Veg.	54.7	60.9	53.9	54.9	61.8	53.0					
	Baum	72.8	61.7	64.1	68.0	66.6	64.3	ΔOA_{DA}^U	ΔOA_{TD}^U	ΔOA_{DA}^{NT}	ΔOA_{TD}^{NT}	
	Sons.	8.5	13.4	8.6	7.9	13.7	8.4					Verbesserung $V_{DA}^{NT} - V_{DA}^U$
	OA [%]	Med.	71.3			71.4			-0.1	10.4	-	9.3
	MW	68.4			69.3			-0.7	13.6	0.2	12.7	0.9
	Std.	11.7			12.0			5.0	11.9	1.1	11.8	-
Pool2	Vers.	77.1	78.2	76.3	81.4	76.8	77.8					
	Geb.	90.4	87.7	88.6	88.9	88.5	88.2					
	N.Veg.	61.6	62.4	60.1	65.7	62.8	62.7					
	Baum	68.2	62.6	63.9	60.8	66.5	61.8	ΔOA_{DA}^U	ΔOA_{TD}^U	ΔOA_{DA}^{NT}	ΔOA_{TD}^{NT}	
	Sons.	3.1	5.2	2.7	2.8	6.0	2.6					Verbesserung $V_{DA}^{NT} - V_{DA}^U$
	OA [%]	Med.	75.0			75.6			-0.3	7.1	-	6.6
	MW	73.5			74.7			-1.2	9.3	0.0	8.2	1.1
	Std.	8.4			7.6			4.5	7.6	1.9	6.3	-
Pool5	Vers.	73.6	75.6	72.8	78.1	73.2	73.6					
	Geb.	87.3	83.9	85.0	85.4	85.1	84.6					
	N.Veg.	57.0	60.1	55.1	59.2	60.7	56.3					
	Baum	66.7	59.9	60.6	60.3	64.2	59.1	ΔOA_{DA}^U	ΔOA_{TD}^U	ΔOA_{DA}^{NT}	ΔOA_{TD}^{NT}	
	Sons.	3.7	5.1	3.0	3.2	5.7	2.9					Verbesserung $V_{DA}^{NT} - V_{DA}^U$
	OA [%]	Med.	70.5			71.4			-0.3	11.2	-	10.4
	MW	69.9			71.0			-1.0	12.7	0.1	11.6	1.0
	Std.	9.1			8.8			5.0	8.7	1.9	8.1	-

36.4% für Kacheln des Testgebietes *Nienburg* in der Zieldomäne. Die Vollständigkeit über alle Testgebiete ist am besten bei Nutzung der Kacheln der Testgebiete *Buxtehude* als Quelldomäne. Dabei liegt der Mittelwert der Vollständigkeit bei 88.9%. Die beste Qualität der Prädiktion von NT auf Basis des $F1$ -Maßes von 79.9% im Mittel über alle Testgebiete wird damit für Kacheln des Testgebietes *Hannover* in der Zieldomäne erzielt. Dabei liegt das $F1$ -Maß für die Kacheln aller Testgebiete außer *Potsdam* in der Quelldomäne über 84%. Eine hohe Qualität der Prädiktion auf Basis des $F1$ -Maßes von 71.6% im Mittel über alle Testgebiete wird außerdem für Kacheln des Testgebietes *Buxtehude* in der Quelldomäne erreicht. Der Wert des $F1$ -Maßes ist am schlechtesten bei Nutzung der Kacheln des Testgebietes *Nienburg* (Mittelwert bei 44.1%) als Zieldomäne, wobei dies in erster Linie an schlechter Korrektheit der Prädiktion von NT liegt. Ein guter $F1$ -Wert der Prädiktion von NT von 83.4% wird außerdem zwischen den Kacheln aus dem Testgebiet *Vaihingen* als Quelldomäne und Kacheln aus dem Testgebiet *Potsdam* als Zieldomäne erreicht. Dagegen liegt der $F1$ -Wert der Prädiktion von NT zwischen den Kacheln aus dem Testgebiet *Potsdam* als Quelldomäne und Kacheln aus dem Testgebiet *Vaihingen* als Zieldomäne nur bei 53.7%. Die entwickelte Strategie zur Prädiktion von NT stellt gewisse Anforderungen an die Qualität der Referenzdaten in der Quelldomäne, auf deren Basis der initiale Klassifikator angelehrt wird, der seinerseits eine Grundlage für die Verschiebung der Merkmalsausprägungen in den beiden Domänen darstellt. Gibt es zum Beispiel starke Überlappungen der Klassenverteilungen, die beim Training auf gelabelten Quelldaten nicht aufgelöst werden können, kann dies die Schätzung des MMD_m -Wertes verfälschen. Solche Überlappungen der Klassen *Baum* und *Niedrige Vegetation* wurden im Kapitel 6.3.4 für den *Potsdam* Datensatz diskutiert. Eine Bestätigung für diese Behauptung stellt der schlechteste $F1$ -Wert der Prädiktion von nur 56.1% für die Kacheln des Testgebietes *Hannover* in der Quelldomäne, der aufgrund der Qualität der Daten auch starke Überlappungen aufweist (siehe Kapitel 6.3.4). Vergleicht man weiterhin die $F1$ -Werte der Prädiktion von NT und die Ergebnisse für $\Delta OADA$ nach der Adaption, so erkennt man, dass für die Testgebietkombinationen mit einem NT über 2% in $\Delta OADA$ (siehe $\Delta OADA$ aus Tabelle 6.28) meist sehr gute $F1$ -Werte von etwa 80% (vgl. mit $F1$ -Wert aus Tabelle 6.39) mit der vorgeschlagenen Strategie erzielt werden. Damit scheint die Strategie bei größeren Diskrepanzen zwischen den Verteilungen der Daten aus der Quell- und Zieldomäne, die in einem größeren negativen Wert von $\Delta OADA$ resultieren, effektiver zu sein. Zwei Beispiele für eine falsche und eine richtige Prädiktion von NT sind in den Abbildungen 6.45 und 6.46 vorgestellt. Die zugehörigen Merkmalsräume wurden zur Veranschaulichung auf die zwei wichtigsten Merkmale $nDOM$ und $NDVI$ reduziert. In dem ersten Fall in Abbildung 6.45 ist der Unterschied zwischen Quell- und Zieldomäne in den Verteilungen im Merkmalsraum deutlich zu erkennen. Dieser Unterschied wurde auch mit einem relativ großen Wert der MMD_m von 0.589 abgeschätzt, der gemäß dem ausgewählten Schwellwert $\tau_{MMD_m}^{Pred} = 0.235$ auf einen NT hinweist. Es ist jedoch dem DA Ansatz gelungen diesen Unterschied auszugleichen und eine Verbesserung der Qualität in der Zieldomäne zu erreichen. Dieses Ergebnis entspricht aus der der Sicht der Prädiktion von NT einem FP. In der Abbildung 6.46 sind die Verteilungen der Quell- und Zieldomäne relativ ähnlich. Die Schätzung der MMD_m führt zu einem Wert von 0.170, der auf einen positiven Transfer hindeutet und letztendlich eine richtige (entspricht TP) Prädiktion aufweist.

Tabelle 6.39: Qualität der Prädiktion von NT. Die Tabelle zeigt die Qualitätsmaße Vollständigkeit, Korrektheit und $F1$ -Maß bei der Prädiktion von NT. Testgebiete: *Vaihingen* (Vai), *Potsdam* (Pot), *Buxtehude* (Bux), *Hannover* (Han) und *Nienburg* (Nie). MW steht für Mittelwert.

Comp		Ziel					
[%]		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	49.7	83.3	96.2	90.3	65.0	76.9
	Pot	79.7	44.1	84.9	63.8	92.9	73.1
	Bux	93.4	79.8	71.4	100.0	100.0	88.9
	Han	91.3	65.8	84.6	72.7	75.0	77.9
	Nie	72.7	93.4	68.8	82.6	12.5	66.0
	MW	77.4	73.3	81.2	81.9	69.1	76.6

Vollständigkeit

Corr		Ziel					
[%]		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	64.5	83.6	35.2	81.3	47.3	62.4
	Pot	40.4	54.6	52.3	48.4	59.8	51.1
	Bux	66.3	88.2	83.3	76.0	20.0	66.8
	Han	26.9	39.1	50.0	100.0	30.0	49.2
	Nie	46.2	67.9	73.3	95.0	25.0	61.5
	MW	48.9	66.7	58.8	80.1	36.4	58.2

Korrektheit

$F1$ -Maß		Ziel					
[%]		Vai	Pot	Bux	Han	Nie	MW
Quelle	Vai	56.1	83.4	51.5	85.5	54.7	66.2
	Pot	53.7	48.8	64.7	55.0	72.7	59.0
	Bux	77.6	83.8	76.9	86.4	33.3	71.6
	Han	41.6	49.0	62.9	84.2	42.9	56.1
	Nie	56.5	78.6	71.0	88.4	16.7	62.2
	MW	57.1	68.7	65.4	79.9	44.1	63.0

$F1$ -Maß

6.4.4 Diskussion

Die Experimente in diesem Kapitel zeigen, dass es möglich ist, die Fälle von NT mit der vorgeschlagenen Strategie vorherzusagen. Die Strategie basiert auf einer Schätzung der Unterschiede zwischen den Verteilungen der Merkmalsvektoren zweier Domänen und erfordert keine Labels in der Zieldomäne. Die entwickelte Strategie auf Basis der modifizierten MMD_m -Metrik zur Prädiktion von NT hatte bereits die beste Korrelation unter den alternativen in Kapitel 6.2.2 untersuchten Strategien gezeigt. Die in der Tabelle 6.37 gezeigten klassenspezifischen Qualitätsmaße der Prädiktion von NT mit einem durchschnittlichen $F1$ -Wert von etwa 60% sind trotzdem nicht ganz zufriedenstellend. Die Analyse mit der linearen Regression hat eine bessere Korrelation der MMD_m -Metrik zu ΔOA_{TD} gezeigt. Damit ist die MMD_m -Metrik ein besserer Prädiktor für den Verlust ΔOA_{TD} aufgrund der fehlenden Trainingsdaten in der Zieldomäne. So liegt z.B. der Mittelwert von ΔOA_{TD} für die Tests anhand des POOL5 Datensatzes, die MMD_m -Werte größer als 0.4 (371 Tests) aufweisen, bei 18.7%. Hingegen liegt der Mittelwert von ΔOA_{TD} für die Tests, deren MMD_m -Werte kleiner als 0.2 (459 Tests) sind, bei nur 4.8%. Die Definition von NT auf Basis von ΔOA_{DA} ist jedoch von ΔOA_{TD} unabhängig und erlaubt keine Verwendung dieser Tatsache in Rahmen dieser Arbeit. Man könnte jedoch diese Tatsache in zukünftigen Arbeiten als Hinweis darauf verwenden, dass man bei größeren MMD_m -Werten gelabelte Trainingsdaten für die Zieldomäne produzieren soll, um den Klassifikator direkt darauf anzulernen.

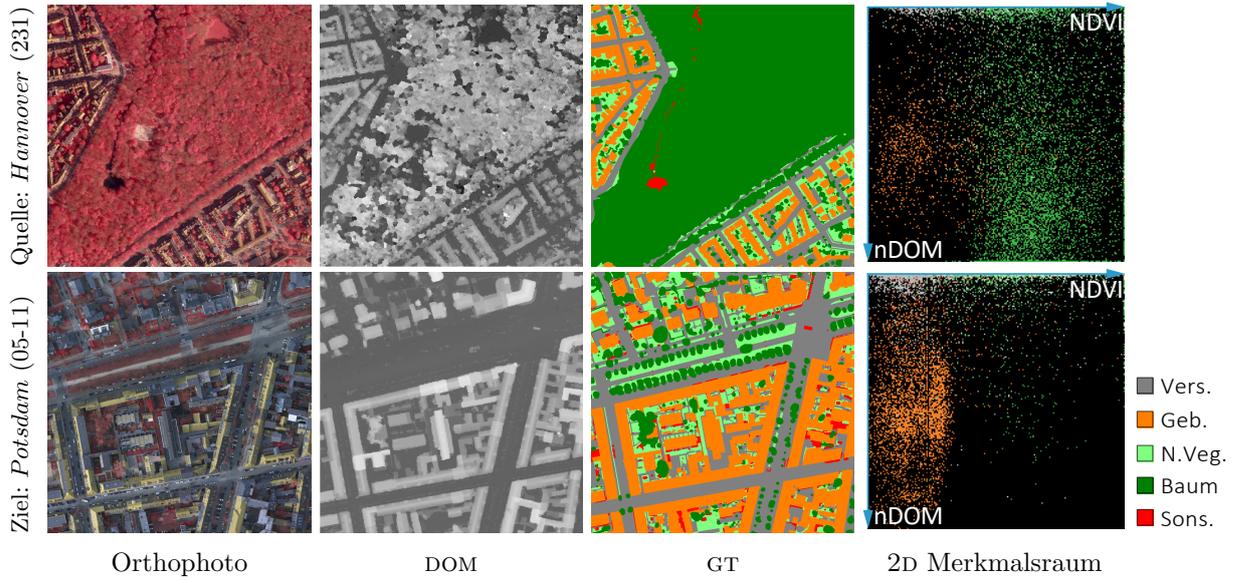


Abbildung 6.45: Exemplarisches Ergebnis der Prädiktion von NT mit Kachel 231 aus dem Testgebiet *Hannover* als Quelldomäne und die Kachel 05_11 aus dem Testgebiet *Potsdam* als Zieldomäne. Die zugehörigen Merkmalsräume sind zur Veranschaulichung auf zwei Merkmale nDOM und NDVI reduziert. Exakte Werte zur Beurteilung der Qualität der Prädiktion für das Beispiel sind in Tabelle 6.40 zusammengefasst.

Tabelle 6.40: Tabelle zeigt Distanzmaß MMD_m sowie Genauigkeitswerte vor (links) und nach der Prädiktion von NT (rechts) für Beispiel aus Abbildung 6.45. Das Distanzmaß zwischen den Verteilungen der Quell- und Zieldomäne wurde mit einem relativ großen Wert der MMD_m von 0.589 abgeschätzt, der gemäß dem ausgewählten Schwellwert $\tau_{MMD_m}^{Pred} = 0.235$ auf einen NT hinweist. Es ist jedoch dem DA Ansatz gelungen diesen Unterschied auszugleichen und eine Verbesserung der Qualität in der Zieldomäne zu erreichen. Damit ist die Prädiktion in diesem Fall fehlgeschlagen.

		Original			Nach Prädiktion von NT mit $\tau_{MMD_m}^{Pred} = 0.235$			
OA_{TT}	OA_{ST}	OA_{DA}	ΔOA_{DA}	ΔOA_{TD}	MMD_m	$OA_{DA}^{MMD_m}$	$\Delta OA_{DA}^{MMD_m}$	$\Delta OA_{TD}^{MMD_m}$
82.3%	62.2%	73.7%	11.5%	8.7%	0.589	62.2%	0.0%	20.1%

Nichtsdestotrotz wurde durch die vorgeschlagene Strategie ein großer Teil der Fälle von NT erkannt und eine kleine Verbesserung auch in dem ΔOA_{DA} -Wert nach der Prädiktion für jeden der untersuchten Datensätze erreicht. Bei einer separaten Betrachtung der unterschiedlichen Testgebiete lag der $F1$ -Wert der Prädiktion von NT gleich für mehrere Testgebiete nah bei und über 80% (vgl. Tabelle 6.39). Durch die Prädiktion von NT konnte im Mittel ein leicht positiver Transfer von 0.1% jeweils für den *Potsdam* und den *POOL5* Datensatz und positiver Transfer von 0.2% für den *3CITYDS* Datensatz erreicht werden. Die erzielten Werte von ΔOA_{DA} entsprechen einer Verbesserung der Genauigkeit von 0.6%, 0.4%, 0.9%, 1.1% bzw. 1.0% auf dem *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* bzw. dem *POOL5* Datensatz gegenüber der Genauigkeit ohne Prädiktion (vgl. Tabelle 6.38). Dementsprechend haben sich nach der Prädiktion auch die mittleren Werte von ΔOA_{TD} verbessert: auf 4.2%, 6.1%, 12.7%, 8.2% bzw. 11.4% für den *Vaihingen*, *Potsdam*, *3CITYDS*, *POOL2* bzw. den *POOL5* Datensatz (vgl. Tabelle 6.38).

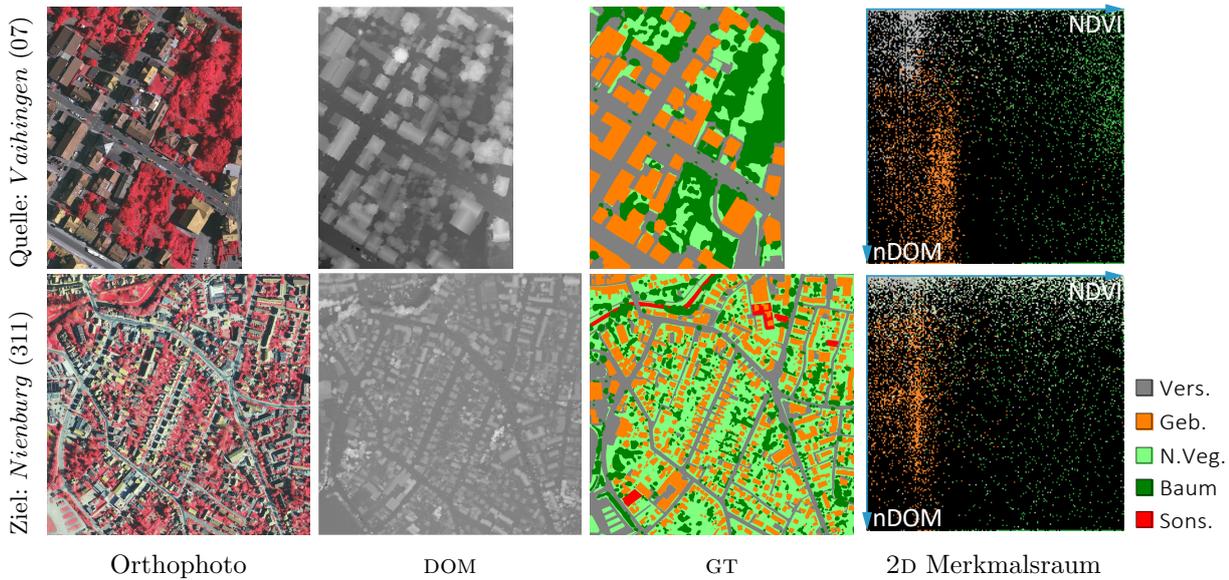


Abbildung 6.46: Exemplarisches Ergebnis der Prädiktion von NT mit Kachel 07 aus dem Testgebiet *Vaihingen* als Quelldomäne und Kachel 311 aus dem Testgebiet *Nienburg* als Zieldomäne. Die zugehörigen Merkmalsräume sind zur Veranschaulichung auf zwei Merkmale $nDOM$ und $NDVI$ reduziert. Exakte Werte zur Beurteilung der Qualität der Prädiktion für das Beispiel sind in Tabelle 6.41 zusammengefasst.

Tabelle 6.41: Tabelle zeigt Distanzmaß MMD_m sowie Genauigkeitswerte vor (links) und nach der Prädiktion von NT (rechts) für Beispiel aus Abbildung 6.46. Das Distanzmaß zwischen den Verteilungen der Quell- und Zieldomäne wurde mit einem MMD_m -Wert von 0.170 abgeschätzt, der gemäß dem Schwellwert $\tau_{MMD_m}^{Pred} = 0.235$ auf einen positiven Transfer hinweist, der auch tatsächlich stattgefunden hat. Damit war die Prädiktion in diesem Fall erfolgreich.

Original					Nach Prädiktion von NT mit $\tau_{MMD_m}^{Pred} = 0.235$			
OA_{TT}	OA_{ST}	OA_{DA}	ΔOA_{DA}	ΔOA_{TD}	MMD_m	$OA_{DA}^{MMD_m}$	$\Delta OA_{DA}^{MMD_m}$	$\Delta OA_{TD}^{MMD_m}$
78.4%	62.3%	66.0%	3.7%	12.4%	0.170	66.0%	3.7%	12.4%

6.5 Vergleich mit Standardverfahren

6.5.1 Zielsetzung

In diesem Abschnitt wird der entwickelte Ansatz zur DA mit einem alternativen Verfahren aus Bruzzone und Prieto [2001] verglichen. Die Autoren gehen dabei von einem GMM als Modell für die Verteilung der Daten aus, dessen Parameter auf Basis der EM an einer Quelldomäne angelernt und an die Verteilung der neuen Daten aus der Zieldomäne angepasst werden. Der Ansatz ist relativ einfach und liefert laut Bruzzone und Prieto [2001] gute Ergebnisse. Allerdings wurde der Ansatz nur auf einem Paar an multitemporalen Satellitenbildern eines Gebietes getestet. Das erste Ziel im Rahmen dieses Experimentes besteht darin, die Ergebnisse dieses Standardverfahrens denen aus dem hier entwickelten DA Ansatz gegenüberzustellen. Ein weiteres Ziel ist die Überprüfung der Hypothese, dass die probabilistischen diskriminativen Klassifikatoren und der vorgestellte Ansatz zur DA auf Basis der LR mit weniger Trainingsdaten auskommen können als ein generatives Modell (siehe Kapitel 3.2).

6.5.2 Durchführung der Experimente

Vorgehensweise bei der Untersuchung. Die experimentelle Untersuchung besteht aus zwei Teilen. Im ersten Teil der Untersuchung findet ein Vergleich der beiden Ansätze zur DA statt. Für das Experiment werden die Bildkacheln des Testgebietes *Potsdam* verwendet. Ein Vergleich der beiden Ansätze findet auf Basis von Perzentil-Plots als Funktion von ΔOA_{DA} , sowie durch eine direkte Gegenüberstellung deren mittleren Gesamtgenauigkeiten statt. Dabei werden dieselben Trainingsdaten aus der Quell- und Zieldomäne für beide Ansätze verwendet. Die Auswahl der gelabelten Stichproben (Trainingsbeispiele) für die Quelldomäne sowie der ungelabelten Stichproben für die Zieldomäne erfolgt mit Rasterweite $RW = 25$ (entspricht 22500 Stichproben pro Domäne). Es wird weiterhin beim alternativen DA-Ansatz auf Basis des ML-Klassifikators für die GMM ein Cluster pro Klasse verwendet. Eine Untersuchung des Ansatzes in [Görler, 2018] hat ergeben, dass dieser mit einem Cluster pro Klasse die besten Ergebnisse auf den gegebenen Daten liefert. Für den DA Ansatz wurden die optimalen Einstellungen aus Tabelle 6.13 übernommen.

Im zweiten Teil der Untersuchung findet die Überprüfung der Hypothese statt, dass der vorgestellte probabilistische diskriminative Ansatz zur DA auf Basis der LR mit weniger Trainingsdaten auskommen kann als der generative DA-Ansatz auf Basis des ML-Klassifikators. Zum Zweck der Überprüfung der Hypothese werden die Ergebnisse der DA auf Basis der beiden Ansätze als Funktion von der Anzahl der Trainingsbeispiele gegenübergestellt. Damit kann überprüft werden, ob bzw. bei welcher Anzahl an Trainingsbeispielen die beiden Verfahren vergleichbare Ergebnisse liefern. Die Auswertung der Variante V_{SS} dient der Beurteilung der Qualität des Trainings, während die Auswertung der Variante V_{DA} Rückschlüsse auf die Qualität der DA der beiden Ansätze ausgehend von der Anzahl der Trainingsbeispiele erlaubt.

Datensätze. Die Untersuchung erfolgt auf dem *Potsdam* Datensatz $\mathfrak{D}_{\mathfrak{U}_5}^{Pot}$. Dabei ist die Menge der verwendeten Bildkacheln aus dem Testgebiet *Potsdam*, die im Datensatz $\mathfrak{D}_{\mathfrak{U}_1}^{Pot}$ zur Optimierung der Parametereinstellungen verwendet wurde (siehe Kapitel 6.1), zu der Menge der Bildkacheln $\mathfrak{D}_{\mathfrak{U}_5}^{Pot}$ disjunkt. Detaillierte Informationen zu dem Datensatz sind in der Tabelle 6.42 zu finden.

Tabelle 6.42: Übersicht über dem *Potsdam* Datensatz $\mathfrak{D}_{\mathfrak{U}_5}^{Pot}$, der bei der Untersuchung in diesem Abschnitt verwendet wird. Für den Datensatz wurden bestimmte Kacheln aus dem Testgebiet *Potsdam* ausgewählt, deren Anzahl in Spalte *#Kacheln* zu finden ist. Die ausgewählten Kacheln sind hier entsprechend der Kodierung aus Abbildung 5.2 aufgelistet. Die Gesamtmenge der Tests steht in Spalte *#Tests*.

Datensatz	#Kacheln	#Tests	Testgebiet	Kachel-Nrn.
$\mathfrak{D}_{\mathfrak{U}_5}^{Pot}$	19	361	Potsdam	02_10, 02_12, 02_14, 03_11, 03_13, 04_10, 04_12, 04_14, 05_11, 05_13, 05_15, 06_08, 06_10, 06_12, 06_14, 07_07, 07_09, 07_11, 07_13

Quelle und Ziel. Im Kontext der DA wird hier mit Quelle S jene Kachel gemeint, an deren Daten der initiale Klassifikator trainiert wird. Als Ziel T wird die Kachel bezeichnet, die zum Testen der DA zum Einsatz kommt. Im Rahmen dieser Untersuchung stehen Labels nur für die Daten aus der Quelldomäne zur Verfügung. Die Klassenlabels für die Daten aus der Zieldomäne werden nur zur Auswertung der Genauigkeiten verwendet.

Testreihe. In dem jeweiligen Experiment findet die Untersuchung an einer Testreihe statt. Bei jedem Test der Testreihe wird eine Kachel aus dem verwendeten Datensatz als Quelldomäne und eine Kachel als Zieldomäne gewählt. Alle möglichen Kombinationen von Kacheln bilden eine Testreihe, wobei die Verwendung derselben Kachel für Quell- und Zieldomäne möglich ist.

Bewertungskriterien. Zum Vergleich der beiden Ansätze werden der Perzentil-Plot, Gesamtgenauigkeiten OA_{SS} , OA_{ST} und OA_{DA} sowie Änderung der Genauigkeit ΔOA_{DA} verwendet.

6.5.3 Ergebnisse

Vergleich der Ansätze. Im ersten Teil der Untersuchung findet ein Vergleich der beiden Ansätze zur DA statt. Die Ergebnisse des Vergleichs der beiden DA Verfahren sind in Abbildung 6.47 und Tabelle 6.43 präsentiert. Das in dieser Arbeit entwickelte Verfahren auf Basis der LR (als *DA-LR* gekennzeichnet) erreicht auf dem *Potsdam* Datensatz in 55% der Tests einen positiven Transfer. Das Vergleichsverfahren auf Basis des ML-Klassifikators (als *DA-ML* gekennzeichnet) erreicht dagegen nur in 15% der Tests einen positiven Transfer. Der Mittelwert von OA_{DA} für *DA-LR* liegt bei 75.2% gegenüber 65.3% für *DA-ML*. Damit erreicht das in dieser Arbeit entwickelte Verfahren eine um ca. 10% bessere Genauigkeit als das Vergleichsverfahren, bei einem Unterschied in den Ausgangsgenauigkeiten $OA_{ST}^{DA-LR} - OA_{ST}^{DA-ML}$ von nur 3.7%. Die Medianwerte von OA_{DA} liegen bei 76.3% für die *DA-LR* und bei 69.0% für die *DA-ML*. Der große Unterschied zwischen dem Mittelwert und Median von OA_{DA} bei der *DA-ML* deuten auf mehrere Ausreißer in den Ergebnissen der Testreihe mit kleineren Werten hin. Allerdings zeigt die *DA-ML* gegenüber der *DA-LR* eine bessere Adaption, wenn es zum positiven Transfer kommt, also etwas bessere ΔOA_{DA} -Werte. Die *DA-LR* erreicht z.B. in 8% der Test einen positiven Transfer von mehr als 2% in OA ($\Delta OA_{DA} > 2\%$), demgegenüber liegt diese Zahl für die *DA-ML* bei 11% der Tests (siehe Perzentil-Plot aus Abbildung 6.47). Die Streuungswerte von OA_{SS} und OA_{ST} sind bei den beiden Verfahren etwa gleich, während die Streuung für OA_{DA} bei der *DA-ML* mit 13.0% fast doppelt so hoch ist wie die bei der *DA-LR*. Der Median und Mittelwert von ΔOA_{DA} liegen für die *DA-ML* bei -3.8% bzw. -6.5% und signalisieren damit einen relativ hohen NT über die gesamte Testreihe. Bei der *DA-LR* liegt der Mittelwert von ΔOA_{DA} bei -0.3% , während der Median den Wert 0.2% erreicht. Damit wird für mehr als Hälfte der Tests bei der Adaption mit dem in dieser Arbeit entwickelten Ansatz ein positiver Transfer erreicht. Diese Ergebnisse bestätigen, dass der hier entwickelte Ansatz dem Vergleichsverfahren auf Basis des ML-Klassifikators weit überlegen ist.

Untersuchungen zur Menge der Trainingsdaten. Im zweiten Teil der Untersuchung findet die Überprüfung der Hypothese statt, dass die probabilistische diskriminative Klassifikatoren, die durch den vorgestellten Ansatz zur DA auf Basis der LR vertreten sind, mit weniger Trainingsdaten als ein generatives Verfahren wie das Alternativverfahren auf Basis des ML-Klassifikators auskommen können. Zum Zweck der Überprüfung werden die Ergebnisse der Validierung der beiden Verfahren in den Varianten V_{SS} und V_{DA} bei variabler Anzahl der Trainingsbeispiele gegenübergestellt. Die Auswertung der Variante V_{SS} dient dabei der Beurteilung der Qualität

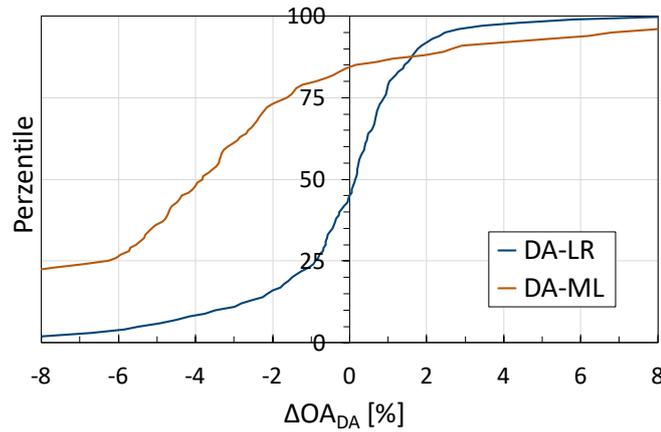


Abbildung 6.47: Vergleich der Ergebnisse nach DA von dem entwickelten Ansatz auf Basis der LR (DA-LR) mit einem Standardverfahren auf Basis des ML-Klassifikators (DA-ML) [Bruzzone und Prieto, 2001]. Ergebnisse sind als Perzentil-Plots über alle Werte ΔOA_{DA} aus der Testreihe dargestellt. Relevanten Genauigkeitswerte sind in Tabelle 6.43 aufgeführt.

Tabelle 6.43: Vergleich der Ergebnisse nach DA von dem entwickelten Ansatz (DA-LR) mit einem Standardverfahren (DA-ML). Tabelle zeigt Genauigkeitswerte OA_{TT} , OA_{ST} und OA_{DA} sowie Qualitätsmaß der DA (ΔOA_{DA}) für den jeweiligen Ansatz (Med.: Median; MW: Mittelwert; Min: Minimum; Max: Maximum; Std: Standardabweichung).

OA [%]	DA-LR				DA-ML			
	OA_{SS}	OA_{ST}	OA_{DA}	ΔOA_{DA}	OA_{SS}	OA_{ST}	OA_{DA}	ΔOA_{DA}
Med.	81.4	76.4	76.3	0.2	76.4	73.0	69.0	-3.8
MW	81.7	75.5	75.2	-0.3	76.6	71.8	65.3	-6.5
Min	75.0	48.9	46.7		68.7	42.1	10.8	
Max	87.1	87.1	87.7		82.8	82.9	77.3	
Std	3.2	6.7	7.2		3.7	7.2	13.0	

des Trainings, während die Auswertung der Variante V_{DA} Rückschlüsse auf die Qualität der DA erlaubt. Die verwendeten Trainings- und Testdaten sind für beide Datensätze identisch, ihre Auswahl erfolgt mit der Strategie der systematischen Ziehung. Die Anzahl der jeweiligen Stichproben ist dabei quadratisch und umgekehrt proportional zu RW . Im Experiment wurde die Anzahl der Trainingsbeispiele sukzessiv durch Reduktion des Wertes von RW von 50 bis 10 erhöht. Der Untersuchungsbereich erstreckte sich dadurch von 5625 bis 140625 Trainingsbeispielen, was einem Anteil von 0.04% bis 1.0% der Gesamtzahl der Pixel in einer Bildkachel der jeweiligen Domäne entspricht. Die Auswertung der Ergebnisse für eine Testreihe mit der fixierten Rasterweite RW erfolgt auf Basis des Medians der erzielten Gesamtgenauigkeiten (OA), da der Median sich gegenüber den Ausreißern robuster als Mittelwert verhält. Die Ergebnisse des Vergleichs sind in Abbildung 6.48 für die Varianten V_{SS} und V_{DA} dargestellt. Die Ergebnisse von OA_{SS} zeigen einen Trend zur Verbesserung der Genauigkeit bei einer steigenden Anzahl an Trainingsdaten. Dabei steigt der Wert von OA_{SS} im Bereich von 5625 ($RW = 50$) bis 140625 ($RW = 10$) Trainingsbeispielen für die Variante mit dem ML-Klassifikator um 1.2% auf 76.9% und für die Variante mit der LR um 1.3% auf 82.0. Damit zeigt die LR auf im ganzen Verlauf etwa um 5% bessere Ergebnisse. Es kann somit bestätigt werden, dass der diskriminative Ansatz auf Basis der LR weniger Trainingsdaten als der generative Ansatz auf Basis des ML-Klassifikators

braucht, um eine qualitativ hochwertigeres Modell zu trainieren.

Die Ergebnisse von OA_{DA} aus Abbildung 6.48 zeigen für $DA-ML$ einen leichten Trend zur Verbesserung der Genauigkeit bei einer steigenden Anzahl an Trainingsdaten. Der Median von OA_{DA} für die $DA-ML$ steigt im Bereich von 5625 ($RW = 50$) bis 140625 ($RW = 10$) Trainingsbeispielen um 0.5% auf 69.1%. Der Median von OA_{DA} für die $DA-LR$ fällt dagegen im selben Bereich um 0.7% auf 75.5%, liegt jedoch immer noch besser als das Ergebnis von $DA-ML$. Damit bestätigen diese Ergebnisse, dass die LR als Basisklassifikator sowohl beim Training als auch beim entwickelten DA Ansatz mit weniger Trainingsdaten als das Vergleichsverfahren auf Basis des ML-Klassifikators auskommen und dabei bessere Ergebnisse liefern kann.

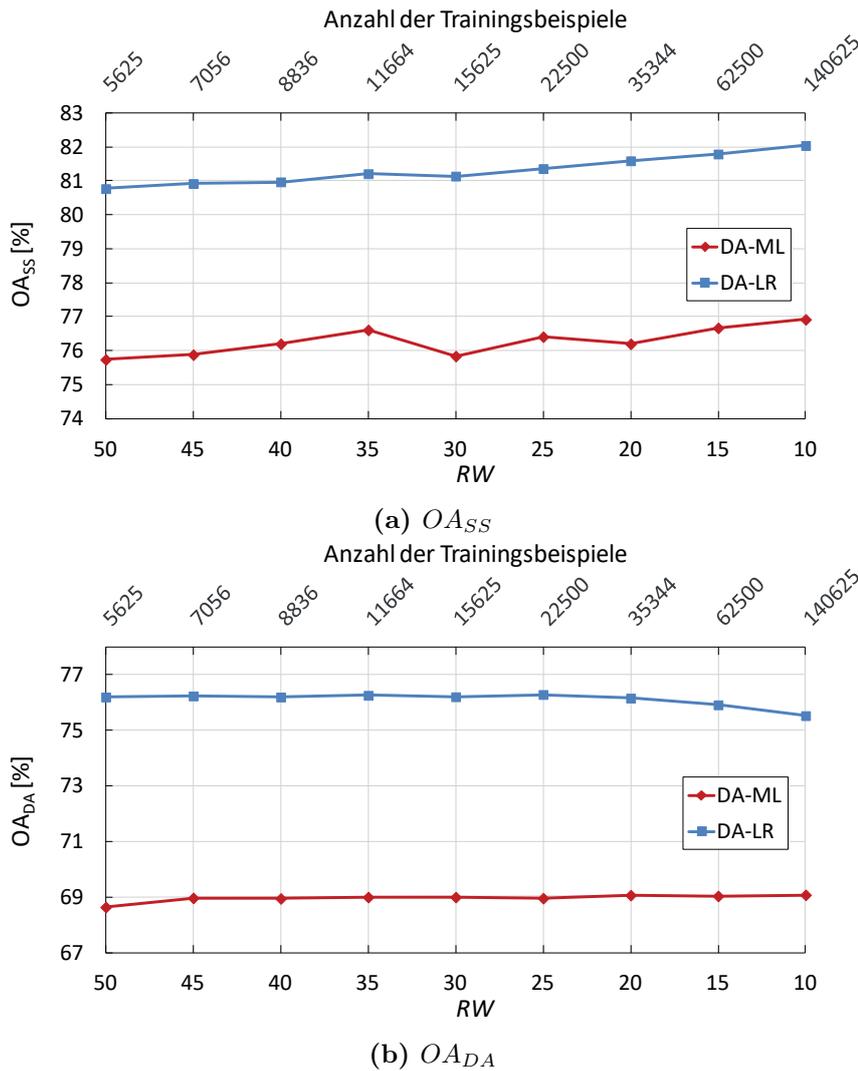


Abbildung 6.48: Ergebnisse des Vergleichs des diskriminativen Ansatzes auf Basis der LR ($DA-LR$) und des generativen Ansatzes auf Basis des ML-Klassifikators ($DA-ML$). Die Abbildung zeigt die Medianwerte für die Variante V_{SS} (a) und für die Variante Variante V_{DA} nach der DA (b) als Funktion von der Anzahl der Trainingsbeispiele.

7 Zusammenfassung und Ausblick

In dieser Arbeit wurde ein neuer Ansatz für die Domänenadaption zur Klassifikation von Luftbildern vorgestellt. Der Klassifikator wird dabei auf Bilddaten aus der Quelldomäne angelernet, für die gelabelte Trainingsdaten vorliegen, und auf die zu klassifizierende Szene aus der Zieldomäne übertragen, in der keine solche Labels zur Verfügung stehen. Die Bilddaten aus der Quell- und Zieldomäne können untereinander räumlich und/oder zeitlich disjunkt sein, sich in Bezug auf Beleuchtungsverhältnisse und saisonale Effekte unterscheiden und den Gebieten angehören, die unterschiedliche Bebauungsstruktur und Grad der Urbanisierung aufweisen. Der DA-Ansatz basiert auf dem Transfer von Instanzen. Dabei wird ein initial auf einer Quelldomäne antrainierter Klassifikator unter Verwendung von Instanzen (Trainingsdaten) iterativ an die Verteilung der Daten aus einer Zieldomäne angepasst. Der iterative Algorithmus wurde von Bruzzone und Marconcini [2010] inspiriert, die eine SVM als Basisklassifikator verwenden. Im Rahmen dieser Arbeit wird ein diskriminativer Ansatz mit einem probabilistischen Output auf Basis der LR als Basisklassifikator ausgewählt. Ein diskriminativer Ansatz wird ausgewählt, weil er gegenüber den generativen Klassifikatoren mit weniger Trainingsdaten auskommen kann. Gegenüber den anderen diskriminativen Klassifikatoren, wie SVM oder RF, bietet die LR den Vorteil, dass sie schnell ist, eine geringe Rechenkomplexität aufweist und direkt einen probabilistischen Output für die Klassenzugehörigkeit als a-posteriori Wahrscheinlichkeiten für Objektklassen bei gegebenen Daten liefert. Nach dem initialen Training des Klassifikators wird die LR in jeder Iteration an einem Trainingsdatensatz umtrainiert, in dem Instanzen aus der Quelldomäne sukzessive durch Instanzen der Zieldomäne ersetzt werden. Dabei bekommen die Instanzen der Zieldomäne Semi-Labels basierend auf dem aktuellen Zustand des Klassifikators zugewiesen. Eine Veränderung des Trainingsdatensatzes ermöglicht somit eine iterative Anpassung des Klassifikators an die Verteilung der Daten aus der Zieldomäne. Die Anpassung des hybriden Trainingsdatensatzes erfordert gut überlegte Strategien zur Auswahl der auszutauschenden Instanzen, um eine erfolgreiche Adaption zu ermöglichen. Als Kriterium zur Auswahl der Trainingsbeispiele aus der Quelldomäne, die aus dem Trainingsdatensatz gelöscht werden, dient ein Maß für den Abstand zur Entscheidungsgrenze, das direkt aus dem probabilistischen Output des Klassifikators für jedes Trainingsbeispiel abgeleitet wird. Mit dem Kriterium werden Trainingsbeispiele, die näher an die Entscheidungsgrenze liegen, erst in späteren Iterationen aus dem Trainingsdatensatz gelöscht, um plötzliche Änderungen der Parameter und somit der Entscheidungsgrenze zu vermeiden. Bei der Auswahl der Trainingsdaten aus der Zieldomäne kommt eine Clusteranalyse zum Einsatz, die lokale Besonderheiten von Verteilungen berücksichtigt. Damit sollen zunächst semi-gelabelte Trainingsbeispiele bevorzugt werden, die in dem aktuellen Trainingsdatensatz nahe an die lokalen Clusterzentren liegen und die aktuelle Entscheidungsgrenze unterstützen. Erst

danach werden semi-gelabelte Trainingsbeispiele hinzugefügt, die spezifisch für die Verteilung der Daten aus der Zieldomäne sind und die resultierende Entscheidungsgrenze verändern. Um plötzliche Änderungen der Parameter beim Austausch von Instanzen zu vermeiden, werden die Instanzen in dem Trainingsdatensatz gewichtet. Durch kleinere Gewichte wird der Einfluss von unsicheren Instanzen auf die Entscheidungsgrenze reduziert und umgekehrt. Die Gewichte werden dabei direkt in die Kostenfunktion der LR integriert und beeinträchtigen somit kaum die Rechenkomplexität.

Mangelnde Ähnlichkeit zwischen den Verteilungen der Quell- und Zieldomäne kann zu einer Situation führen, in der die Verwendung vom Quellwissen das Lernen in der Zieldomäne verschlechtern würde. Als Folge kann ein Einbrechen der Adaptionqualität und sogar ein NT resultieren. Die Erkennung bzw. Vermeidung von NT ist ein wichtiger Bestandteil einer erfolgreichen Adaption. Die hier entwickelte Strategie zur Erkennung von NT basiert auf einer Erweiterung der MMD Distanzmetrik zwischen zwei Randverteilungen und kann ohne Labels in der Zieldomäne auskommen. Der verwendete Ansatz verfolgt die Idee, die a-posteriori Wahrscheinlichkeit der Klassen bei gegebenen Daten aus der Quelldomäne in den Prädiktionsprozess für eine verbesserte Erkennung von NT auf der Zieldomäne einzubeziehen.

Die experimentellen Untersuchungen des entwickelten semi-überwachten DA Ansatzes auf Basis der LR fanden auf fünf verschiedenen Datensätzen statt, die aus Bilddaten von fünf verschiedenen Testgebieten zusammengestellt wurden. Der erreichte Anteil von positivem Transfer ($\Delta OA_{DA} \geq 0\%$) lag auf verschiedenen Datensätzen bei etwa 50% aller Testfälle, während er für das Testgebiet *Potsdam*, an dem die Parametereinstellungen untersucht wurden, bei 56% lag. Bei Adaption des Klassifikators zwischen den Kacheln aus unterschiedlichen Testgebieten wurde im Mittel über alle Datensätze ein positiver Transfer in ca. 43% der Tests erreicht. Außerdem resultiert ein positiver Transfer in rund 47% der Tests, in denen die Bildkacheln der Quell- und Zieldomäne Testgebieten mit unterschiedlicher GSD gehören. Damit haben die experimentellen Untersuchungen gezeigt, dass ein Transfer zwischen verschiedenen Gebieten, deren Bilddaten sich in Bezug auf die Bebauungsstruktur der Städte, sowie Aufnahmesensorik, Lichtverhältnisse, saisonale Effekte und Auflösung der Daten (Bodenpixelgröße) unterscheiden, möglich ist.

Die Experimente haben außerdem gezeigt, dass der Genauigkeitsverlust gegenüber einem erneut anhand von gelabelten Trainingsdaten in der Zieldomäne angelernten Klassifikator (ΔOA_{TD}) nur für homogene Datensätze (ein Testgebiet) und innerhalb der einzelnen Testgebiete relativ klein gehalten werden kann. Bei inhomogenen Datensätzen wie 3CITYDS, POOL2 und POOL5 lag der Median von ΔOA_{TD} über 7%. Betrachtet man nur die Fälle vom positiven Transfer, dann liegt der Wert vom Median für diese Datensätze zwischen ca. 4% und 8% in ΔOA_{TD}^+ . Diese Ergebnisse zeigen, dass noch Verbesserungsbedarf besteht.

Grundsätzlich lässt sich in den experimentellen Ergebnissen erkennen, dass nicht alle Kombinationen der Bildkacheln in der Quell- und Zieldomäne von dem Einsatz der vorgestellten Methode zur DA profitieren. Eine Reihe von Faktoren sind für die Qualität der Adaption von entscheidender Bedeutung. Zum einen wirken sich große Unterschiede in den Verteilungen der beiden Domänen, die die Ähnlichkeitsbedingung der DA verletzen, negativ auf das Ergebnis der DA bis

hin zum NT aus. Ursachen für die Unterschiede können in den veränderten Sensorcharakteristiken, Beleuchtungsverhältnissen, saisonalen Effekten oder regionalen Unterschieden zwischen den Aufnahmen aus der Quell- und Zieldomäne liegen. Dabei könnte in den Experimenten beobachtet werden, dass vor allem große saisonale Unterschiede zu den verschiedenen Verteilungen der Merkmalsvektoren in den beiden Domänen führen können und eine Verminderung der Qualität der Adaption nach sich ziehen können. Außerdem haben die Experimente gezeigt, dass eine starke Überlappung der Merkmalsausprägungen der einzelnen Klassen untereinander sowohl in Quell- als auch in der Zieldomäne zu Problemen führt. Eine solche Überlappung kann dazu führen, dass die Verteilungen solcher Klassen sogar unter Einbeziehung der Labels fürs Training mit der LR nicht gut von einander getrennt werden können. Weiterhin soll auf das Problem der unterrepräsentierten Klassen bei der DA auf Basis der LR sorgfältig eingegangen werden. Solche Klassen können z.B. aufgrund der Unterschiede zwischen Quell- und Zieldomäne einfacher einer falschen Klasse während der DA zugeteilt werden, da die Semi-Labels auf Basis einer lokalen Analyse im Merkmalsraum (von K -NN und aus dem aktuellen Zustand des Klassifikators) zugewiesen werden. Des Weiteren haben die Experimente betont, dass die Verwendung einer gleichen Klassenstruktur bei der entwickelten Methode zwingend eingehalten werden muss. So wirkt sich ein Unterschied in der Menge der vorhandenen Objektarten zwischen der Quell- und Zieldomäne von einer einzigen Klasse bereits stark negativ auf die Qualität der Adaption aus. Darüber hinaus wird durch die experimentelle Untersuchungen die Notwendigkeit der geeigneten Strategien zur Prädiktion und Vermeidung von NT unterstrichen.

Die Experimente zur Prädiktion von NT haben erwiesen, dass es möglich ist, Fälle von NT vorherzusagen. Für die vorgeschlagene Strategie auf Basis der MMD Distanzmetrik mit Modifikation der Verteilung wurde zunächst gezeigt, dass durch die vorgeschlagene Modifikation ein besseres Merkmal zur Prädiktion von NT erzeugt wird. Weiterhin hat sich diese Strategie im Rahmen der Experimente auf einem der Datensätze erfolgreich gegenüber den vergleichbaren Standardverfahren zur Prädiktion von NT bewiesen und erreichte dabei eine verbesserte Prädiktionsgenauigkeit. Durch die Prädiktion von NT konnte die mittlere Genauigkeit der Adaption auf jedem der untersuchten Evaluierungsdatensätze verbessert werden. Trotzdem ist die gezeigte Prädiktionsleistung nicht ganz zufriedenstellend. Die erwünschte Korrelation zwischen dem Maß ΔOA_{DA} für die Güte der Adaption und dem verwendeten MMD_m Distanzmaß zwischen den Verteilungen aus der Quell- und Zieldomäne fällt nur schwach aus. Es werden somit durch die Prädiktion mit einem Schwellwert auch viele Fälle mit einer guten Adaptionsleistung aussortiert. Die Experimente haben gezeigt, dass die MMD_m -Metrik ein besserer Prädiktor für den Verlust aufgrund der fehlenden Trainingsdaten in der Zieldomäne ΔOA_{TD} als für ΔOA_{DA} ist.

Zur Verbesserung der DA auf Basis der LR zur Klassifikation von Luftbildern sind eine Reihe von Untersuchungen vorstellbar, auf die im Folgenden eingegangen wird.

Der vorgestellte Ansatz wurde speziell zur Klassifikation von Luftbildern konzipiert. Der Ansatz macht jedoch keine datenspezifischen Annahmen. Damit ist die Anwendung der vorgestellten DA nicht nur auf Luftbilder begrenzt. Der Ansatz könnte ohne großen Aufwand auf andere vergleichbare Sensordaten, wie Satellitenbilder, übertragen werden. Es ist ebenso eine Adaption

zwischen Bilddaten, deren Merkmalsverteilungen die Ähnlichkeitsbedingung erfüllen, aus einem anderen Anwendungsbereich als Fernerkundung vorstellbar. Weiterhin haben die Experimente gezeigt, dass die Unterschiede in den Merkmalsverteilungen gelegentlich auf die Ungenauigkeiten in den Eingangsdaten zurückzuführen sind. Somit könnte eine höhere Qualität der Daten bereits zu einer verbesserten Klassifikationsgenauigkeit nach der Adaption führen: z.B. durch Verwendung eines TOP statt eines DOP oder von genaueren DOM-Daten sowohl in der Quell- als auch Zieldomäne. Außerdem könnte die Verwendung weiterer Merkmale im Adaptionsprozess die Diskrepanz zwischen den überlappenden Merkmalsausprägungen der einzelnen Klassen in der Quell- und Zieldomäne und folglich die Qualität der Adaption selbst weiter verbessern.

Die fehlenden Labels in der Zieldomäne stellen den größten limitierenden Faktor für die Qualität der DA dar. Sollte es möglich sein, gelabelte Daten in der Zieldomäne zusätzlich zu den Labels in der Quelldomäne kostengünstig zu erhalten, wäre es für die Genauigkeit der Anpassung vom Vorteil. Die gelabelten Daten aus der Zieldomäne könnten auch zur Anpassung im Rahmen des vorgestellten Ansatzes eingesetzt werden, z.B. indem solche Daten mit einem festen Label (bis zur Ende der DA) möglichst früh unter Zuweisung eines höheren initialen Gewichtes in den aktuellen Trainingsdatensatz hinzugefügt werden. Außerdem wäre es denkbar, Daten aus der Quelldomäne im Trainingsdatensatz, die im Merkmalsraum nah an gelabelten Daten aus der Zieldomäne liegen, ebenso stärker zu gewichten. Schließlich können die Labels in der Zieldomäne auch zur Verbesserung der Prädiktion von NT ausgenutzt werden. Neben einer überwachten DA könnten dann die Methoden des Aktiven Lernens [Settles, 2012] (siehe Abschnitt 3.1.1) eingesetzt werden, falls es die Möglichkeit besteht, für eine wohlüberlegte Auswahl der Stichproben aus der Zieldomäne Labels zu erhalten. Dies erlaubt zwar nicht, auf Labeling komplett zu verzichten, kann aber den Aufwand dafür erheblich reduzieren.

Eine weitere Alternative stellen die Methoden der DEEP DA, wie z.B. der semi-überwachte Ansatz zur pixelweisen Klassifikation von Fernerkundungsbildern aus [Wittich und Rottensteiner, 2019]. Diese Methoden sollen unter der Voraussetzung eingesetzt werden, dass eine größere Menge an den gelabelten Trainingsdaten vorhanden ist, deren Verteilung zu jener der Zieldomäne ähnlich ist. Dabei wird versucht, eine gegen möglichst viele Einflüsse invariante Repräsentation der Merkmalsvektoren (Bilder) zu finden, damit eine anschließende Klassifikation möglichst unabhängig von der jeweiligen Domäne stattfinden kann.

Ein wichtiger Aspekt, der sich auf die Qualität der DA im Rahmen dieser Arbeit auswirkt, ist die Auswahl der auszutauschenden Instanzen. Damit können weitere Auswahlstrategien untersucht werden, um die Anpassung des Klassifikators auf die Verteilung der Daten aus der Zieldomäne zu verbessern. Es könnte z.B. ein weiterer Term in die Bewertungsfunktion integriert werden, mit dem die Auswahl der Instanzen aus der Zieldomäne in der Nähe der aktuellen Entscheidungsgrenze vermieden, jedoch nicht gänzlich verworfen werden soll. Damit würden diese Instanzen erst später im Verlauf der Adaption in den Trainingsdatensatz übernommen. Die Idee hinter dem Vorschlag basiert darauf, dass aufgrund der unterschiedlichen Verteilungen in der Quell- und Zieldomäne die Wahrscheinlichkeit für einen richtig zugewiesenen Semi-Label für solche Instanzen zu Beginn der iterativen Anpassung des Klassifikators relativ klein ist. Es könnte wiederum der probabilistische Output des Klassifikators als Maß für den Abstand von

der Entscheidungsgrenze verwendet werden. Man könnte dafür die Instanzen in der jeweiligen Iteration in Abhängigkeit von deren a-posteriori Wahrscheinlichkeit einordnen und die ersten n Instanzen im Rahmen der Funktion zur Auswahl der Instanzen niedriger bewerten. Es ist bei der Auswahl von Instanzen ebenso wichtig, die Genauigkeit der Schätzung von Semi-Labels für die Instanzen aus der Zieldomäne zu verbessern. Hier könnte z.B. in Kombination zu der bereits verwendeten K - NN Analyse ein Ensemble aus verschiedenen Clusteringverfahren, ähnlich zu [Acharya et al., 2011], verwendet werden, die eine konsolidierte Entscheidung über die geschätzte Klassenzugehörigkeit liefern.

Die experimentellen Untersuchungen haben gezeigt, dass der vorgeschlagener Ansatz zu DA auf Basis der LR meist eine schlechtere Adaptionsqualität für unterrepräsentierte Klassen aufweist. Das Problem resultiert im Allgemeinen daraus, dass beim Lernen der LR alle Trainingsbeispiele einen Einfluss auf das Ergebnis und die Lage der Entscheidungsgrenze haben. Dabei üben unterrepräsentierte Klassen einen schwächeren Einfluss auf die Entscheidungsgrenze aus. Um das Problem anzugehen, könnte wiederum das Framework zur Gewichtung der Instanzen verwendet werden, mit dessen Hilfe Instanzen in Abhängigkeit von dem jeweiligen Anteil der Stichproben innerhalb der zugehörigen Klasse in der Quell- bzw. Zieldomäne gewichtet werden. Dabei sollen unterrepräsentierte Klassen höhere Gewichte erhalten. Der Anteil der Instanzen in der jeweiligen Klasse aus der Quelldomäne kann mit Hilfe der vorhandenen Labels ermittelt werden. Da es jedoch keine Labels in der Zieldomäne vorliegen, müssen der Anteil der Instanzen pro Klasse und somit die Gewichte für semi-gelabelte Trainingsbeispiele aus der Zieldomäne anders bestimmt werden. Es könnte z.B. Annahme getroffen werden, dass die Klassenverteilungen der Quell- und Zieldomäne gleich sind. Dann würde man dieselben Gewichte für Instanzen der gleichen Klassen aus der Quell- und Zieldomäne verwenden. Eine solche Annahme kann jedoch nicht immer eingehalten werden, dann muss der Anteil der Instanzen in der jeweiligen Klasse abgeschätzt werden. Hier könnten zusätzliche Informationen zu der jeweiligen Klassenverteilung, z.B. aus einem Clusterverfahren, eine Abhilfe schaffen.

Im Rahmen der experimentellen Untersuchung hat sich außerdem gezeigt, dass die Einbeziehung vom Kontext sich positiv auf die Qualität der Adaption auswirken kann. Der Kontext könnte alternativ mit Hilfe von Conditional Random Field (CRF) [Kumar und Hebert, 2006] berücksichtigt werden. Der angepasste Klassifikator könnte dabei das Modell für Daten- und Interaktionsterme zur Optimierung der a-posteriori Wahrscheinlichkeit des CRF für die kontextbasierte Klassifikation liefern.

Schließlich haben die Experimente zu NT angedeutet, dass die entwickelte MMD_m -Metrik ein besserer Prädiktor für den Verlust der Genauigkeit ΔOA_{TD} aufgrund der fehlenden Trainingsdaten in der Zieldomäne ist. Man könnte diese Tatsache in zukünftigen Arbeiten als Hinweis darauf verwenden, dass man bei größeren MMD_m -Werten gelabelte Trainingsdaten für die Zieldomäne produzieren soll, um den Klassifikator direkt darauf anzulernen.

Literaturverzeichnis

- Abe, S., 2010. *Support Vector Machines for Pattern Classification*. 2nd edn, Springer, New York (NY), USA.
- Acharya, A., Hruschka, E. R., Ghosh, J. and Acharya, S., 2011. C3E: A framework for combining ensembles of classifiers and clusterers. In: *Multiple Classifier Systems*, Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 269–278.
- Acharya, A., Hruschka, E. R., Ghosh, J. and Acharya, S., 2012. Transfer learning with cluster ensembles. In: *Proceedings of the ICML Workshop on Unsupervised and Transfer Learning*, Bellevue (WA), USA, pp. 123–133.
- Bahirat, K., Bovolo, F., Bruzzone, L. and Chaudhuri, S., 2012. A novel domain adaptation bayesian classifier for updating land-cover maps with class differences in source and target domains. *IEEE Transactions on Geoscience and Remote Sensing* 50(7), pp. 2810–2826.
- Baralis, E., Chiusano, S. and Garza, P., 2008. A lazy approach to associative classification. *IEEE Transactions on Knowledge and Data Engineering* 20(2), pp. 156–171.
- Bejiga, M. B. and Melgani, F., 2018. GAN-based domain adaptation for object classification. In: *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 1264–1267.
- Bentley, J. L., 1975. Multidimensional binary search trees used for associative searching. *Communications of the ACM* 18(9), pp. 509–517.
- Bishop, C. M., 2006. *Pattern Recognition and Machine Learning*. 1st edn, Springer, New York (NY), USA.
- Breiman, L., 1996. Bagging predictors. *Machine Learning* 24(2), pp. 123–140.
- Breiman, L., 2001. Random forests. *Machine Learning* 45(1), pp. 5–32.
- Bruzzone, L. and Cossu, R., 2002. A multiple-cascade-classifier system for a robust and partially unsupervised updating of land-cover maps. *IEEE Transactions on Geoscience and Remote Sensing* 40(9), pp. 1984–1996.
- Bruzzone, L. and Marconcini, M., 2009. Toward the automatic updating of land-cover maps by a domain-adaptation SVM classifier and a circular validation strategy. *IEEE Transactions on Geoscience and Remote Sensing* 47(4), pp. 1108–1122.
- Bruzzone, L. and Marconcini, M., 2010. Domain adaptation problems: A DASVM classification technique and a circular validation strategy. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 32(5), pp. 770–787.
- Bruzzone, L. and Persello, C., 2009. A novel approach to the selection of spatially invariant features for the classification of hyperspectral images with improved generalization capability. *IEEE Transactions on Geoscience and Remote Sensing* 47(9), pp. 3180–3191.
- Bruzzone, L. and Prieto, D., 2001. Unsupervised retraining of a maximum likelihood classifier for the analysis of multitemporal remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing* 39(2), pp. 456–460.
- Bruzzone, L. and Prieto, D. F., 2002. A partially unsupervised cascade classifier for the analysis of multitemporal remote-sensing images. *Pattern Recognition Letters* 23(9), pp. 1063 – 1071.
- Bruzzone, L., Chi, M. and Marconcini, M., 2006. A novel transductive SVM for semisupervised classification of remote-sensing images. *IEEE Transactions on Geoscience and Remote Sensing* 44(11), pp. 3363–3373.
- Bruzzone, L., Cossu, R. and Vernazza, G., 2002. Combining parametric and non-parametric algorithms for a partially unsupervised classification of multitemporal remote-sensing images. *Information Fusion* 3(4), pp. 289 – 297.
- Burger, W. and Burge, M., 2005. *Digitale Bildverarbeitung: Eine Einführung mit Java und ImageJ*. Springer Berlin-Heidelberg, Berlin, Heidelberg.
- Camps-Valls, G., Bandos Marsheva, T. and Zhou, D., 2007. Semi-supervised graph-based hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing* 45(10), pp. 3044–3054.
- Chang, M.-W., Lin, C.-J. and Weng, R. C., 2002. Analysis of switching dynamics with competing support vector machines. In: *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, Vol. 3, pp. 2387–2392.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L. and Stein, C., 2009. Greedy algorithms. In: *Introduction to Algorithms*, 3rd edn, MIT Press, Cambridge (MA), USA, pp. 414–450.
- Cortes, C. and Vapnik, V., 1995. Support-vector networks. *Machine Learning* 20(3), pp. 273–297.
- Csurka, G., 2017. A comprehensive survey on domain adaptation for visual applications. In: *Domain Adaptation in Computer Vision Applications*, Springer International Publishing, Cham, Switzerland, pp. 1–35.
- Dai, W., Yang, Q., Xue, G.-R. and Yu, Y., 2007. Boosting for transfer learning. In: *International Conference on Machine Learning (ICML)*, pp. 193–200.
- Davis, J. and Goadrich, M., 2006. The relationship between precision-recall and ROC curves. In: *International Conference on Machine Learning (ICML)*, pp. 233–240.

- Decoste, D. and Schölkopf, B., 2002. Training invariant support vector machines. *Machine Learning* 46(1), pp. 161–190.
- Duan, L., Tsang, I. W. and Xu, D., 2012. Domain transfer multiple kernel learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 34(3), pp. 465–479.
- Eaton, E. and desJardins, M., 2011. Selective transfer between learning tasks using task-based boosting. In: *Proceedings of the Conference on Artificial Intelligence (AAAI)*, pp. 337–342.
- Eaton, E., desJardins, M. and Lane, T., 2008. Modeling transfer relationships between learning tasks for improved inductive transfer. In: *European Conference on Machine Learning (ECML)*, Springer Berlin-Heidelberg, Berlin, Heidelberg, pp. 317–332.
- Fahrmeir, L., Heumann, C., Künstler, R., Pigeot, I. and Tutz, G., 2016. Regressionsanalyse. In: *Statistik: Der Weg zur Datenanalyse*, Springer Berlin-Heidelberg, Berlin, Heidelberg, pp. 437–475.
- Fisher, R. A., 1936. The use of multiple measurements in taxonomic problems. *Annals of Eugenics* 7(2), pp. 179–188.
- Fogel, D. B., 1995. *Evolutionary Computation: Toward a New Philosophy of Machine Intelligence*. IEEE Press, Piscataway (NJ), USA.
- Frenay, B. and Verleysen, M., 2014. Classification in the presence of label noise: A survey. *IEEE Transactions on Neural Networks and Learning Systems* 25(5), pp. 845–869.
- Ge, L., Gao, J., Ngo, H., Li, K. and Zhang, A., 2014. On handling negative transfer and imbalanced distributions in multiple source transfer learning. *Statistical Analysis and Data Mining: The ASA Data Science Journal* 7(4), pp. 254–271.
- Gomez-Chova, L., Camps-Valls, G., Munoz-Mari, J. and Calpe, J., 2008. Semisupervised image classification with Laplacian support vector machines. *IEEE Geoscience and Remote Sensing Letters (GRSL)* 5(3), pp. 336–340.
- Gong, B., Shi, Y., Sha, F. and Grauman, K., 2012. Geodesic flow kernel for unsupervised domain adaptation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2066–2073.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y., 2014. Generative adversarial nets. In: *Advances in Neural Information Processing Systems (NIPS)*, Vol. 27, Curran Associates, Inc., Red Hook (NY), USA, pp. 2672–2680.
- Gopalan, R., Li, R. and Chellappa, R., 2011. Domain adaptation for object recognition: An unsupervised approach. In: *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, pp. 999–1006.
- Görler, S., 2018. Untersuchung eines generativen Klassifikators für Domain Adaptation Probleme. Masterarbeit, Leibniz Universität Hannover.
- Gretton, A., Borgwardt, K. M., Rasch, M. J., Schölkopf, B. and Smola, A., 2012. A kernel two-sample test. *Journal of Machine Learning Research* 13(25), pp. 723–773.
- Gretton, A., Bousquet, O., Smola, A. and Schölkopf, B., 2005. Measuring statistical dependence with hilbert-schmidt norms. In: *Algorithmic Learning Theory*, Springer Berlin-Heidelberg, Berlin, Heidelberg, pp. 63–77.
- Hänsch, R. and Hellwich, O., 2017. Random forests. In: *Photogrammetrie und Fernerkundung: Handbuch der Geodäsie*, Springer Berlin-Heidelberg, Berlin, Heidelberg, pp. 603–644.
- Haralick, R. M., Shanmugam, K. and Dinstein, I., 1973. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics* SMC-3(6), pp. 610–621.
- Henze, N., 2013. Grundbegriffe der deskriptiven Statistik. In: *Stochastik für Einsteiger: Eine Einführung in die faszinierende Welt des Zufalls*, Springer Fachmedien Wiesbaden, Wiesbaden, pp. 20–36.
- Hoffman, J., Tzeng, E., Park, T., Zhu, J.-Y., Isola, P., Saenko, K., Efros, A. and Darrell, T., 2018. CyCADA: Cycle-consistent adversarial domain adaptation. In: *International Conference on Machine Learning (ICML)*, pp. 1989–1998.
- Huang, J., Smola, A., Gretton, A., Borgwardt, K. and Schölkopf, B., 2007. Correcting sample selection bias by unlabeled data. In: *Advances in Neural Information Processing Systems (NIPS)*, Vol. 19, MIT Press, Cambridge (MA), USA, pp. 601–608.
- Hughes, G., 1968. On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory* 14(1), pp. 55–63.
- Izquierdo-Verdiguier, E., Laparra, V., Gomez-Chova, L. and Camps-Valls, G., 2013. Encoding invariances in remote sensing image classification with SVM. *IEEE Geoscience and Remote Sensing Letters (GRSL)* 10(5), pp. 981–985.
- Kiefer, J., 1953. Sequential minimax search for a maximum. *Proceedings of the American Mathematical Society* 4(3), pp. 502–506.
- Kim, W. and Crawford, M. M., 2010. Adaptive classification for hyperspectral image data using manifold regularization kernel machines. *IEEE Transactions on Geoscience and Remote Sensing* 48(11), pp. 4110–4121.

- Klein, H. and Förstner, W., 1984. Realization of automatic error detection in the block adjustment program PAT-M43 using robust estimators. *International Archives of Photogrammetry and Remote Sensing* XXV-3a, pp. 234–245.
- Kumar, S. and Hebert, M., 2006. Discriminative random fields. *International Journal of Computer Vision* 68(2), pp. 179–201.
- Kumar, S., Ghosh, J. and Crawford, M. M., 2002. Hierarchical fusion of multiple classifiers for hyperspectral data analysis. *Pattern Analysis & Applications* 5(2), pp. 210–220.
- Kuznetsova, A., Hwang, S. J., Rosenhahn, B. and Sigal, L., 2015. Expanding object detector's horizon: Incremental learning framework for object detection in videos. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 28–36.
- Lawler, G. F. and Limic, V., 2010. *Random walk: a modern introduction*. Cambridge University Press, New York (NY), USA.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. and Jackel, L. D., 1989. Backpropagation applied to handwritten zip code recognition. *Neural Computation* 1(4), pp. 541–551.
- Lee, J., 2010. *Introduction to Topological Manifolds*. Graduate Texts in Mathematics, Springer, New York (NY), USA.
- Leiva-Murillo, J. M., Gomez-Chova, L. and Camps-Valls, G., 2013. Multitask remote sensing data classification. *IEEE Transactions on Geoscience and Remote Sensing* 51(1), pp. 151–161.
- Li, X., Zhang, L., Du, B., Zhang, L. and Shi, Q., 2017. Iterative reweighting heterogeneous transfer learning framework for supervised remote sensing image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10(5), pp. 2022–2035.
- Liu, Q., Liao, X., Carin, H. L., Stack, J. R. and Carin, L., 2009. Semisupervised multitask learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 31(6), pp. 1074–1086.
- Lohr, S., 2009. *Sampling: design and analysis*. Advanced series, Cengage Learning, Boston (MA), USA.
- Long, J., Shelhamer, E. and Darrell, T., 2015. Fully convolutional networks for semantic segmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 3431–3440.
- Maas, A. E., Rottensteiner, F., Alobeid, A. and Heipke, C., 2018. Multitemporal classification under label noise based on outdated maps. *Photogrammetric Engineering & Remote Sensing* 84(5), pp. 263–277.
- Matasci, G., Volpi, M., Kanevski, M., Bruzzone, L. and Tuia, D., 2015. Semisupervised transfer component analysis for domain adaptation in remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing* 53(7), pp. 3550–3564.
- Musa, A. B., 2013. Comparative study on classification performance between support vector machine and logistic regression. *International Journal of Machine Learning and Cybernetics* 4(1), pp. 13–24.
- Othman, E., Bazi, Y., Alajlan, N., AlHichri, H. and Melgani, F., 2016. Three-layer convex network for domain adaptation in multitemporal vhr images. *IEEE Geoscience and Remote Sensing Letters (GRSL)* 13(3), pp. 354–358.
- Pan, S. J. and Yang, Q., 2010. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering* 22(10), pp. 1345–1359.
- Pan, S. J., Tsang, I. W., Kwok, J. T. and Yang, Q., 2011. Domain adaptation via transfer component analysis. *IEEE Transactions on Neural Networks* 22(2), pp. 199–210.
- Patel, V. M., Gopalan, R., Li, R. and Chellappa, R., 2015. Visual domain adaptation: A survey of recent advances. *IEEE Signal Processing Magazine* 32(3), pp. 53–69.
- Paul, A., Rottensteiner, F. and Heipke, C., 2015. Transfer learning based on logistic regression. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XL-3/W3, pp. 145–152.
- Paul, A., Rottensteiner, F. and Heipke, C., 2016. Iterative re-weighted instance transfer for domain adaptation. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* III-3, pp. 339–346.
- Persello, C. and Bruzzone, L., 2016. Kernel-based domain-invariant feature selection in hyperspectral images for transfer learning. *IEEE Transactions on Geoscience and Remote Sensing* 54(5), pp. 2615–2626.
- Powers, D. M. W., 2011. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *Journal of Machine Learning Technologies* 2(1), pp. 37–63.
- Quiñonero-Candela, J., 2009. *Dataset Shift in Machine Learning*. Neural information processing series, MIT Press, Cambridge (MA), USA.
- Rajan, S., Ghosh, J. and Crawford, M. M., 2006. Exploiting class hierarchies for knowledge transfer in hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing* 44(11), pp. 3408–3417.

- Roscher, R. and Förstner, W., 2009. Multiclass bounded logistic regression - efficient regularization with interior point method. Technical Report 2, Department of Photogrammetry, Institute of Geodesy and Geoinformation, University of Bonn.
- Rosenstein, M. T., Marx, Z., Kaelbling, L. P. and Dietterich, T. G., 2005. To transfer or not to transfer. In: *Proceedings of NIPS Workshop on Inductive Transfer: 10 Years Later*, pp. 1–4.
- Rottensteiner, F., 2017. Kontextbasierte Ansätze in der Bildanalyse. In: *Photogrammetrie und Fernerkundung: Handbuch der Geodäsie*, Springer Berlin-Heidelberg, Berlin, Heidelberg, pp. 555–602.
- Rusu, A. A., Rabinowitz, N. C., Desjardins, G., Soyer, H., Kirkpatrick, J., Kavukcuoglu, K., Pascanu, R. and Hadsell, R., 2016. Progressive neural networks. *CoRR, arXiv: 1606.04671*.
- Rutzinger, M., Rottensteiner, F. and Pfeifer, N., 2009. A comparison of evaluation techniques for building extraction from airborne laser scanning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 2(1), pp. 11–20.
- Schapire, R. E., 1990. The strength of weak learnability. *Machine Learning* 5(2), pp. 197–227.
- Seah, C. W., Ong, Y. S. and Tsang, I. W., 2013. Combating negative transfer from predictive distribution differences. *IEEE Transactions on Cybernetics* 43(4), pp. 1153–1165.
- Settles, B., 2012. *Active Learning*. Synthesis Lectures on Artificial Intelligence and Machine Learning, Morgan & Claypool Publishers, San Rafael (CA), USA.
- Shi, J. and Malik, J., 2000. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 22(8), pp. 888–905.
- Shimodaira, H., 2000. Improving predictive inference under covariate shift by weighting the log-likelihood function. *Journal of Statistical Planning and Inference* 90(2), pp. 227 – 244.
- Singh, A., 1989. Review article digital change detection techniques using remotely-sensed data. *International Journal of Remote Sensing* 10(6), pp. 989–1003.
- Sriperumbudur, B. K., Fukumizu, K., Gretton, A., Lanckriet, G. R. G. and Schölkopf, B., 2009. Kernel choice and classifiability for RKHS embeddings of probability distributions. In: *Advances in Neural Information Processing Systems (NIPS)*, Vol. 22, Curran Associates, Inc., Red Hook (NY), USA, pp. 1750–1758.
- Strunz, G., Martinis, S. and Schöpfer, E., 2017. Beiträge der Fernerkundung zur Unterstützung des Katastrophenmanagements und der humanitären Hilfe. In: *Photogrammetrie und Fernerkundung: Handbuch der Geodäsie*, Springer Berlin-Heidelberg, Berlin, Heidelberg, pp. 805–840.
- Sugiyama, M., Krauledat, M. and Müller, K.-R., 2007. Covariate shift adaptation by importance weighted cross validation. *Journal of Machine Learning Research* 8(May), pp. 985–1005.
- Sun, H., Liu, S., Zhou, S. and Zou, H., 2016. Transfer sparse subspace analysis for unsupervised cross-view scene model adaptation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9(7), pp. 2901–2909.
- Sun, Z., Wang, C., Wang, H. and Li, J., 2013. Learn multiple-kernel svms for domain adaptation in hyperspectral data. *IEEE Geoscience and Remote Sensing Letters (GRSL)* 10(5), pp. 1224–1228.
- Süße, H. and Rodner, E., 2014. *Bildverarbeitung und Objekterkennung: Computer Vision in Industrie und Medizin*. Springer Fachmedien Wiesbaden, Wiesbaden.
- Swain, P. H., 1978. Bayesian classification in a time-varying environment. *IEEE Transactions on Systems, Man, and Cybernetics* 8(12), pp. 879–883.
- Thrun, S. and Pratt, L., 1998. Learning to learn: Introduction and overview. In: *Learning to Learn*, Kluwer Academic Publishers, Boston (MA), USA, pp. 3–17.
- Tuia, D., 2014. Weakly supervised alignment of image manifolds with semantic ties. In: *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 3546–3549.
- Tuia, D., Munoz-Mari, J., Gomez-Chova, L. and Malo, J., 2013. Graph matching for adaptation in remote sensing. *IEEE Transactions on Geoscience and Remote Sensing* 51(1), pp. 329–341.
- Tuia, D., Pasolli, E. and Emery, W., 2011a. Using active learning to adapt remote sensing image classifiers. *Remote Sensing of the Environment* 115(9), pp. 2232 – 2242.
- Tuia, D., Persello, C. and Bruzzone, L., 2016. Domain adaptation for the classification of remote sensing data: An overview of recent advances. *IEEE Geoscience and Remote Sensing Magazine* 4(2), pp. 41–57.
- Tuia, D., Volpi, M., Copa, L., Kanevski, M. and Munoz-Mari, J., 2011b. A survey of active learning algorithms for supervised remote sensing image classification. *IEEE Journal of Selected Topics in Signal Processing* 5(3), pp. 606–617.

- Tuia, D., Volpi, M., Trollet, M. and Camps-Valls, G., 2014. Semisupervised manifold alignment of multimodal remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing* 52(12), pp. 7708–7720.
- Tzeng, E., Hoffman, J., Saenko, K. and Darrell, T., 2017. Adversarial discriminative domain adaptation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2962–2971.
- Vapnik, V. N., 1998. *Statistical Learning Theory*. Wiley, New York (NY), USA.
- Velleman, P. F. and Hoaglin, D., 1981. *Applications, Basics, and Computing of Exploratory Data Analysis*. Duxbury Press, Boston (MA), USA.
- Vishwanathan, S., Schraudolph, N., Schmidt, M. W. and Murphy, K. P., 2006. Accelerated training of conditional random fields with stochastic gradient methods. In: *International Conference on Machine Learning (ICML)*, pp. 969–976.
- Vogt, K., Paul, A., Ostermann, J., Rottensteiner, F. and Heipke, C., 2018. Unsupervised source selection for domain adaptation. *Photogrammetric Engineering & Remote Sensing* 84(5), pp. 249–261.
- Voisin, A., Krylov, V. A., Moser, G., Serpico, S. B. and Zerubia, J., 2014. Supervised classification of multisensor and multiresolution remote sensing images with a hierarchical copula-based approach. *IEEE Transactions on Geoscience and Remote Sensing* 52(6), pp. 3346–3358.
- Wang, M. and Deng, W., 2018. Deep visual domain adaptation: A survey. *Neurocomputing* 312, pp. 135 – 153.
- Wegner, J. D., Rottensteiner, F., Gerke, M. and Sohn, G., 2016. The ISPRS 2D Labelling Challenge. <http://www2.isprs.org/commissions/comm3/wg4/semantic-labeling.html>. Accessed 05/04/2018.
- Weidner, U. and Förstner, W., 1995. Towards automatic building reconstruction from high resolution digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing* 50(4), pp. 38–49.
- Weiss, K., Khoshgoftaar, T. M. and Wang, D., 2016. A survey of transfer learning. *Journal of Big Data* 3(1), pp. 9: 1–40.
- Wittich, D. and Rottensteiner, F., 2019. Adversarial domain adaptation for the classification of aerial images and height data using convolutional neural networks. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences IV-2/W7*, pp. 197–204.
- Wolf, L. and Bileschi, S., 2006. A critical view of context. *International Journal of Computer Vision* 69(2), pp. 251–261.
- Yan, S., Xu, D., Zhang, B., Zhang, H., Yang, Q. and Lin, S., 2007. Graph embedding and extensions: A general framework for dimensionality reduction. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 29(1), pp. 40–51.
- Yang, H. L. and Crawford, M. M., 2016. Domain adaptation with preservation of manifold geometry for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9(2), pp. 543–555.
- Yao, Y. and Doretto, G., 2010. Boosting for transfer learning with multiple sources. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1855–1862.
- Yin, X., Han, J., Yang, J. and Yu, P. S., 2006. Efficient classification across multiple database relations: a crossmine approach. *IEEE Transactions on Knowledge and Data Engineering* 18(6), pp. 770–783.
- Yosinski, J., Clune, J., Bengio, Y. and Lipson, H., 2014. How transferable are features in deep neural networks? In: *Advances in Neural Information Processing Systems (NIPS)*, Vol. 27, Curran Associates, Inc., Red Hook (NY), USA, pp. 3320–3328.
- Zadrozny, B., 2004. Learning and evaluating classifiers under sample selection bias. In: *International Conference on Machine Learning (ICML)*, pp. 114–121.
- Zahid, F. M. and Tutz, G., 2013. Ridge estimation for multinomial logit models with symmetric side constraints. *Computational Statistics* 28(3), pp. 1017–1034.
- Zhang, Y., Hu, X. and Fang, Y., 2010. Logistic regression for transductive transfer learning from multiple sources. In: L. Cao, J. Zhong and Y. Feng (eds), *Advanced Data Mining and Applications Part II*, Lecture Notes in Computer Science, Vol. 6441, Springer Berlin-Heidelberg, Berlin, Heidelberg, pp. 175–182.
- Zhu, X. X., Tuia, D., Mou, L., Xia, G., Zhang, L., Xu, F. and Fraundorfer, F., 2017. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine* 5(4), pp. 8–36.

Danksagung

An dieser Stelle möchte ich mich bei allen Personen bedanken, die mich in den letzten Jahren bei der Erstellung dieser Arbeit direkt und indirekt unterstützt haben.

Mein besonderer herzlicher Dank gilt meinem Doktorvater apl. Prof. Dr. techn. Franz Rottensteiner für die intensive fachliche Betreuung, motivierende Gespräche und Hilfe beim Verfassen der Texte.

Darüber hinaus möchte ich mich bei Prof. Dr.-Ing. Jörn Ostermann für die sehr gute Zusammenarbeit im institutsübergreifenden Projekt im Rahmen dieser Arbeit sowie die Übernahme des Korreferats bedanken. Herrn apl. Prof. Dr.-Ing. Claus Brenner danke ich für die Übernahme des Korreferats sowie wertvolle inhaltliche Vorschläge.

Außerdem möchte ich mich bei Prof. Dr.-Ing. Christian Heipke für viele fachliche Diskussionen und Vorschläge sowie für die Übernahme des Vorsitzes der Prüfungskommission bedanken.

Weiterhin danke ich der International Society for Photogrammetry and Remote Sensing (ISPRS), dem Landesamt für Geoinformation und Landesvermessung Niedersachsen (LGLN) und dem Institut für Informationsverarbeitung (TNT) für die Bereitstellung der Testdatensätze, des Bildmaterials bzw. der Referenzdaten zur Evaluierung des vorliegenden Ansatzes.

Bei Karsten Vogt vom TNT möchte ich mich für die sehr aufschlussreiche und angenehme Kollaboration am gemeinsamen institutsübergreifenden Projekt bedanken.

Allen Kolleginnen und Kollegen am Institut für Photogrammetrie und GeoInformation (IPI) der Leibniz Universität Hannover möchte ich für die gute Zusammenarbeit und tolle Arbeitsatmosphäre danken. Bei Claudia Sander und Annette Radtke möchte ich mich für die freundliche Unterstützung bei Lösung diverser organisatorischer Angelegenheiten bedanken. Für viele Auskünfte und Beistand in zahlreichen Fragen rund um das Institut mochte ich außerdem Manfred Wiggenhagen danken. Für viele wertvolle fachliche Diskussionen, gesellige Gespräche und gemeinsame Aktivitäten möchte ich mich bei meinen über die Zeit wechselnden Bürokolleginnen und Kollegen Lukas Schack, Martin Reich, Mirjana Voelsen und Alina Maas bedanken. Alina danke ich außerdem für viele fachliche Anregungen und Vorschläge, aber auch für ihre Freundschaft.

Ganz besonders möchte ich mich bei meinen Eltern, meinem Bruder und seiner Familie für ihre uneingeschränkte Unterstützung bedanken. Mein abschließender Dank gilt meiner Frau für ihre grenzenlose Liebe, den Rückhalt und ihren verständnisvollen Umgang in schwierigen Zeiten.

Lebenslauf

Persönliches

Andreas Paul

Geboren am 02. Februar 1984 in Pawlodar, Kasachstan

Berufserfahrung

- | | |
|-------------------|--|
| 08/2014 - 12/2019 | Wissenschaftlicher Mitarbeiter am Institut für Photogrammetrie und GeoInformation, Leibniz Universität Hannover, Deutschland |
| 01/2014 - 03/2014 | Wissenschaftliche Hilfskraft am Lehrstuhl für Bildverarbeitung, Rheinisch-Westfälische Technische Hochschule Aachen, Deutschland |
| 01/2012 - 09/2012 | Studentische Hilfskraft am Institut für Stromrichtertechnik und Elektrische Antriebe, Rheinisch-Westfälische Technische Hochschule Aachen, Deutschland |
| 03/2011 - 08/2011 | Industriepraktikum bei Continental AG, Berlin, Deutschland |

Ausbildung

- | | |
|-------------------|---|
| 10/2005 - 11/2013 | Studium der Technischen Informatik an der Rheinisch-Westfälischen Technischen Hochschule Aachen, Deutschland. Abschluss: Diplom |
| 09/2004 - 07/2005 | Staatliches Studienkolleg für ausländische Studierende an der Rheinisch-Westfälischen Technischen Hochschule Aachen, Deutschland. Abschluss: Fachabitur |
| 09/2001 - 08/2002 | Staatliche Universität in Pawlodar, Kasachstan. Fachrichtung: Automatisierung und Informationsversorgung in Steuerungssystemen |
| 09/1991 - 07/2001 | Schulbildung, Pawlodar, Kasachstan. Abschluss: Allgemeine Hochschulreife |

Wissenschaftliche Arbeiten der Fachrichtung Geodäsie und Geoinformatik der Leibniz Universität Hannover

(Eine vollständige Liste der Wiss. Arb. ist beim Geodätischen Institut, Nienburger Str. 1, 30167 Hannover erhältlich.)

- Nr. 333 VON GÖSSELN, Ilka: Simulationsbasierte Effizienzoptimierung von Messprozessen am Beispiel der tachymetrischen Netzmessung (Diss. 2017)
- Nr. 334 HOFMANN, Sabine: Potential von LiDAR Mobile Mapping für hochgenaue Karten (Diss. 2017)
- Nr. 335 ALBERT, Lena: Simultane Klassifikation der Bodenbedeckung und Landnutzung unter Verwendung von Conditional Random Fields (Diss. 2017)
- Nr. 336 NIEMEYER, Joachim: Verwendung von Kontext zur Klassifikation luftgestützter Laserdaten urbaner Gebiete (Diss. 2017)
- Nr. 337 EGGERT, Daniel: Effiziente Verarbeitung und Visualisierung von Mobile Mapping Daten (Diss. 2017)
- Nr. 338 FITZNER, Daniel: Estimation of Spatio-Temporal Moving Fields at High Resolution (Diss. 2017)
- Nr. 339 CZIOSKA, Paul: Meeting point locations for shared rides (Diss. 2018)
- Nr. 340 FEUERHAKE, Udo: Erfassung von Trajektorien und Erkennung von Bewegungsmustern (Diss. 2018)
- Nr. 341 HUANG, Hai : Bayesian Models for Pattern Recognition in Spatial Data (Habil. 2018) .
(Nicht im Layout unserer Schriftenreihe erschienen, sondern als Heft DGK Reihe C, Heft 751)
- Nr. 342 BOCK, Urs Fabian: Dynamic Parking Maps from Vehicular Crowdsensing (Diss. 2018)
- Nr. 343 KRAWINKEL, Thomas: Improved GNSS Navigation with Chip-scale Atomic Clocks (Diss. 2018)
- Nr. 344 GOSWAMI, Sujata: Understanding the sensor noise in the GRACE range-rate observations by analyzing their residuals (Diss. 2018)
- Nr. 345 ZHANG, Yin: Expected Utilities for Decision Making and Steering of Measurement Processes (Diss. 2018)
- Nr. 346 SCHLICHTING, Alexander: Fahrzeuglokalisierung durch Automotive Laserscanner unter Verwendung statischer Merkmale (Diss. 2018)
- Nr. 347 RÖTH, Oliver: Extraktion von hochgenauer Fahrspurgeometrie und -topologie auf der Basis von Fahrzeugtrajektorien und Umgebungsinformationen (Diss. 2018)
- Nr. 348 NEELMEIJER, Julia: Observing Inter- and Intra-Annual Glacier Changes and Lake Loading Effects from Synthetic Aperture Radar Remote Sensing (Diss. 2018)
- Nr. 349 HOBERG, Thorsten: Conditional Random Fields zur Klassifikation multitemporaler Fernerkundungsdaten unterschiedlicher Auflösung (Diss. 2018)
- Nr. 350 SCHILLING, Manuel: Kombination von klassischen Gravimetern mit Quantensensoren (Diss. 2019)
- Nr. 351 MILLER, Dominik: Seismic noise analysis and isolation concepts for the ALPS II experiment at DESY (Diss. 2019)
- Nr. 352 ALI, Bashar: Optimierte Verteilung von Standorten der Schulen unter dem Einfluss des demografischen Wandels am Beispiel Grundschulen (Diss. 2019)
- Nr. 353 ZHAO, Xin: Terrestrial Laser Scanning Data Analysis for Deformation Monitoring (Diss. 2019)
- Nr. 354 HAGHIGHI, Mahmud Haghshenas: Local and Large Scale InSAR Measurement of Ground Surface Deformation (Diss. 2019)
- Nr. 355 BUREICK, Johannes: Robuste Approximation von Laserscan-Profilen mit B-Spline-Kurven (Diss. 2020)
- Nr. 356 BLOTT, Gregor: Multi-View Person Re-Identification (Diss. 2020)
- Nr. 357 MAAS, Alina Elisabeth: Klassifikation multitemporaler Fernerkundungsdaten unter Verwendung fehlerbehafteter topographischer Daten (Diss. 2020)
- Nr. 358 NGUYEN, Uyen: 3D Pedestrian Tracking Using Neighbourhood Constraints (Diss. 2020)
- Nr. 359 KIELER, Birgit: Schema-Matching in räumlichen Datensätzen durch Zuordnung von Objektinstanzen (Diss. 2020)
- Nr. 360 PAUL, Andreas: Domänenadaption zur Klassifikation von Luftbildern (Diss. 2020)

Die Arbeiten werden im Rahmen des wissenschaftlichen Schriftenaustausches verteilt und sind nicht im Buchhandel erhältlich. Der Erwerb ist zu einem Stückpreis von € 25,00 bei den herausgebenden Instituten möglich.

