

Institut für Photogrammetrie und GeoInformation  
Leibniz Universität Hannover

Masterarbeit

## **Kontextbasierte Klassifikation von ALS-Punktwolken**

B.Sc. Katharina Schmunk

Beginn: 12.04.2012  
Abgabe: 12.10.2012

**Betreuer:**

Prof. Dr.-Ing. Uwe Sörgel  
Dipl.-Ing. Joachim Niemeyer

Hannover, 12. Oktober 2012

# **Selbstständigkeitserklärung**

Ich versichere, dass ich die Arbeit selbstständig verfasst und keine anderen als die angegebenen Hilfsmittel benutzt habe.

Hannover, 12. Oktober 2012

Katharina Schmunk

## Kurzfassung

In den letzten Jahren gewinnt das Airborne Laserscanning (ALS) immer mehr auch in städtischen Gebieten an Bedeutung. Die einzelnen Punkte aus der resultierenden Punktwolke können dann in einer Klassifikation anhand ihrer Merkmale in vorgegebene Klassen wie *Boden*, *Gebäude*, *Gebüsch* und *Bäume* zugeordnet werden. Bei aktuellen Verfahren wie die Support Vector Machines (SVM) wird jeder Punkt unabhängig von den anderen Punkten einer Klasse zugeordnet. Durch die neueren kontextbasierten Verfahren - wie die Markov Random Fields (MRF) und Conditional Random Fields (CRF) - wird jeder Punkt in Abhängigkeit von seinen Nachbarpunkten klassifiziert, wodurch eine Verbesserung bei der Klassifikation erreicht werden kann.

Die Klassifikation wird für einen Datensatz in Hannover mit den drei Verfahren SVM, MRF und CRF durchgeführt. Der Vergleich der drei Verfahren zeigt, dass mit den kontextbasierten Verfahren in der Gesamtgenauigkeit bessere Ergebnisse erzielt werden können. Zudem werden noch weitere Analysen in Bezug auf die einzelnen Komponenten der CRF durchgeführt, um nach Möglichkeit die Klassifikationsergebnisse der CRF nochmals zu optimieren. Durch die Verwendung ausgewählter Interaktionsmerkmale, im Speziellen den Höhenunterschieden, konnten in der Klassifikation Verbesserungen erzielt werden. Eine starke Erhöhung der Nachbarschaftsgröße zeigte für das Testgebiet Hannover deutliche Verschlechterungen. Wählt man hingegen zufällige Nachbarn für den Aufbau des Graphen anstatt direkte Nachbarn, so kann ebenfalls eine Verbesserung in der Klassifikation erreicht werden. Weiterhin zeigt sich, dass die Kombination aus der Auswahl der Höhenunterschiede für die Interaktionsmerkmale und die Wahl der zufälligen Nachbarn keinen weiteren Einfluss auf die Ergebnisse mit sich bringt.

Zusammengefasst können mit den kontextbasierten Verfahren bessere Klassifikationsergebnisse erzielt werden als mit dem Verfahren, das ohne Kontext arbeitet. Zudem lassen sich diese Ergebnisse durch bestimmte weitere Maßnahmen nochmals optimieren.

# Inhaltsverzeichnis

1	Einleitung .....	1
1.1	Motivation.....	2
1.2	Ziele und Aufbau der Arbeit.....	3
2	Grundlagen .....	4
2.1	Airborne Laserscanning .....	4
2.2	Aktuelle Klassifikationsverfahren.....	7
2.2.1	Lineare Modelle.....	8
2.2.2	Support Vector Machines.....	10
2.3	Probabilistische Klassifikation mit graphischen Modellen .....	12
2.3.1	Probabilistische Theorie.....	13
2.3.2	Graphische Modelle zur Modellierung von Kontext.....	14
2.3.3	Markov Random Fields.....	17
2.3.4	Conditional Random Fields.....	20
3	Methode.....	23
3.1	Definition des Graphen.....	23
3.2	Merkmale für Knoten und Kanten .....	24
3.3	Training und Inferenz.....	27
4	Experimente.....	30
4.1	Testgebiet.....	30
4.2	Bewertung anhand von Qualitätsmaßen .....	31
4.3	Bestimmung der Nachbarschaftsgröße im Graphen.....	33
4.4	Test zu den Modellen des Cliques- bzw. Interaktionspotentials.....	36
4.5	Vergleich zwischen SVM, MRF und CRF.....	40
4.6	Analyse einzelner CRF-Komponenten.....	45
4.6.1	Verwendung ausgewählter Interaktionsmerkmale.....	45
4.6.2	Erhöhung der Nachbarschaft im Graphen.....	48
4.6.3	Zufällige Auswahl der Nachbarpunkte.....	51
4.6.4	Kombination der besten Konfigurationen.....	55
5	Zusammenfassung und Ausblick.....	58
	Literaturverzeichnis.....	61
	Abbildungsverzeichnis.....	64
	Tabellenverzeichnis.....	66

# 1 Einleitung

Mit der Weiterentwicklung von Technologien der Fernerkundung haben sich die Möglichkeiten zur Erfassung von bewohnten Gebieten vervielfältigt. Die aufgenommenen Daten eignen sich für die Erstellung von dreidimensionalen Stadtmodellen, die wiederum für einfache Visualisierungen oder die Fahrzeugnavigation verwendet werden können. Auch im Bereich der Stadtplanung, Erfassung von Straßennetzwerken, Baumkatastern oder der Erstellung von digitalen Geländemodellen (DGM) können die Daten benutzt werden.

Seit vielen Jahren lassen sich auch kleinere Strukturen wie Bäume, Fahrzeuge etc. in den Städten auflösen. Die Erfassung der Städte durch Satellitenbilder, Luftbilder und Synthetic Aperture Radar gehört schon zum Standard.

Seit den letzten zwei Jahrzehnten [Flood 2001] gewinnt das kommerziell eingesetzte Airborne Laserscanning (ALS) immer mehr an Bedeutung und wird vermehrt bei der Erfassung von Städten eingesetzt. Dabei entstehen Punktwolken, die aus der Luft aufgenommen werden. Mit ALS erreicht man eine hohe Auflösung und eine flächenhafte Aufnahme in 3D. Die Vorteile sind, dass die Daten großflächig erfasst werden können, und dass das System die Daten berührungslos, genau und dicht aufnimmt. Die aktuelle und kommerziell seit 2004 vertriebene Technologie [Hug 2004] ist das full-waveform Laserscanning. Dabei wird das gesamte reflektierte Signal kontinuierlich aufgenommen, wodurch mehr Punkte detektiert und zusätzliche Eigenschaften aus den Daten abgeleitet werden können. Hat man eine dreidimensionale Punktwolke, so müssen die einzelnen Punkte häufig zur besseren Interpretation semantisch zugeordnet werden. Das bedeutet, dass man die Punkte mit Hilfe ihrer Merkmale zum Beispiel in Gebäude, Vegetation und Boden unterteilt. Die Punkte werden in vorher festgelegte Klassen eingeteilt; es findet eine Klassifikation statt.

### **1.1 Motivation**

Eine große Herausforderung stellt die oben genannte Klassifikation der Punktwolke in urbanen Gebieten dar. Besonders in Städten findet man viele verschiedene Objekte, die unterschiedlich geformt und angeordnet sind und zudem noch sehr nahe beieinander liegen. Man findet unterschiedliche Arten von Vegetation, Boden, Umzäunungen, Hecken, Fahrzeuge und andere Objekte. Dabei können nun die Merkmale der full-waveform Daten unterstützend bei der Zuordnung dienen, wenn die Objekte dicht beieinander liegen. Aktuelle Verfahren, wie z.B. die Support Vector Machines, klassifizieren nur mit Hilfe der Merkmale der Punkte. Das heißt, dass jeder Punkt unabhängig von den anderen Punkten zugeordnet wird. Dabei können die Klassifikationsergebnisse besonders in städtischen Gebieten inhomogen sein [Mallet 2010].

Ein weiterer wichtiger Faktor bei der Verbesserung der Klassifikation ist die Nutzung von Kontextwissen. Nach der Definition ist Kontext eine "für die Objekterkennung relevante Information, die sich nicht direkt auf das äußerliche Erscheinungsbild des Objektes zurückführen lässt" [Wolf 2006]. Dabei bedeutet die Modellierung von Kontext nichts anderes als die Berücksichtigung statistischer Abhängigkeiten zwischen benachbarten Punkten bzw. Objekten. Man kann durch die Nachbarschaft modellieren, dass ein Objekt wahrscheinlicher einer bestimmten Klasse zugeordnet wird als einer anderen Klasse. Zum Beispiel lässt sich modellieren, dass die Wahrscheinlichkeit eines Punktes zur Klasse *Gebäude* zu gehören geringer ist, wenn seine Nachbarn der Klasse *Wasser* zugeordnet werden.

In dieser Arbeit werden die kontextbasierten Verfahren Markov Random Fields und Conditional Random Fields untersucht, mit denen die Punktwolke eines full-waveform Laserscanners klassifizieren werden soll.

### **1.2 Ziele und Aufbau der Arbeit**

In dieser Arbeit wird mit Hilfe von drei aktuellen Verfahren zur Klassifikation von Laserpunktwolken untersucht, inwieweit Kontextinformation Ergebnisse der Klassifikation einer Punktwolke optimieren. Als Klassifikationsverfahren werden die kontextbasierten Verfahren Markov Random Fields und Conditional Random Fields angewendet. Zum Vergleich wird außerdem das Verfahren Support Vector Machines, das ohne Kontextinformation arbeitet, eingesetzt. Um die drei unterschiedlichen Verfahren am besten vergleichen zu können, werden überall die gleichen Testbedingungen geschaffen. Zum einen werden in allen Verfahren die linearen Modelle bzw. lineare Support Vector Machines als Klassifikatoren, zum anderen wird immer dasselbe Trainingsgebiet verwendet. Als Testgebiete dient ein Datensatz von Hannover. Es wird untersucht, welche Verbesserung erreicht werden kann, wenn Kontextinformationen verwendet werden. Die Bewertung der Ergebnisse erfolgt nach den klassischen Kriterien wie Korrektheit, Vollständigkeit, Qualität und Gesamtgenauigkeit. Außerdem werden noch zusätzliche Experimente durchgeführt, die der Analyse der Conditional Random Fields dienen sollen.

In Kapitel 2 der Arbeit werden durch die einführende Darstellung des ALS sowie der Verfahren, die ohne und mit Kontext klassifizieren, die Grundlagen dargelegt. Der methodische Teil wird im Kapitel 3 beschrieben. Im nachfolgenden Kapitel werden die unterschiedlichen Experimente erläutert. Das letzte Kapitel 5 enthält eine Zusammenfassung und einen Ausblick auf zukünftige Entwicklungen.

## 2 Grundlagen

Da die Laserpunktwolke grundlegend für diese Arbeit ist, wird zunächst in diesem Abschnitt das Airborne Laserscannings, insbesondere das full-waveform Airborne Laserscanning, erklärt. Die entstandene Punktwolke wird mit Hilfe unterschiedlicher Verfahren klassifiziert. Aktuelle Verfahren, wie die Support Vector Machines, klassifizieren hierbei, ohne dass Kontextinformationen einbezogen werden. Neuere Verfahren, wie die Markov Random Fields und Conditional Random Fields, nutzen Nachbarschaftsbeziehungen für die Klassifikation. In diesem Abschnitt werden die aktuellen sowie die probabilistischen Verfahren zur Klassifikation erläutert.

### 2.1 Airborne Laserscanning

Die Aufnahme der Erdoberfläche und die daraus entstehende Laserpunktwolke erfolgt durch Airborne Laserscanning (ALS). Der Laserscanner basiert auf der LIDAR Technik (Light Detection and Ranging) und ist ein aktiver Sensor. Aktive Sensoren haben die Eigenschaft, dass die Aufnahme von der Sonnenbeleuchtung unabhängig ist. Das Prinzip basiert darauf, dass der Laser ein Lichtsignal von einer Plattform, wie einem Flugzeug oder Satelliten, sendet und dieses an einer Oberfläche




Abb. 2.1: Messprinzip nach [Heipke 2011]

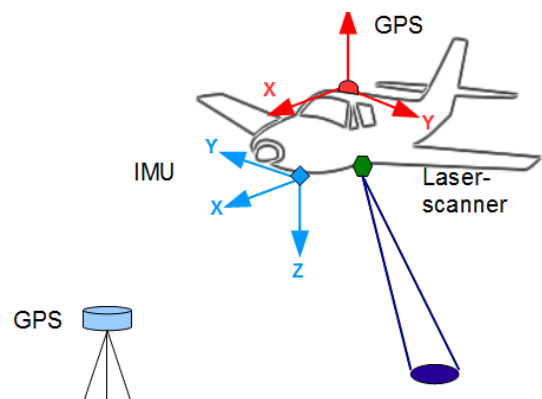


Abb. 2.2: Messeinheiten nach [Heipke 2011]



## 2.1 Airborne Laserscanning

---

reflektiert wird (Abb. 2.1). Aus der direkten Entfernungsmessung, der Position und Orientierung des Laserscanners, erhält man dann die erfassten 3D Punkte, welche die Objekte auf der Oberfläche beschreiben.

Bei der Entfernungsmessung unterscheidet man zwischen zwei verschiedenen Systemen: den Dauerstrich Laserscannern, von denen das Lichtsignal kontinuierlich ausgesendet wird, und den Puls Laserscannern, bei denen das Lichtsignal in kurzen Pulsen (ns) in rascher Folge (kHz) ausgesendet wird [Baltsavias 1999]. Bei den Dauerstrich Laserscannern wird die Entfernung aus der Phasendifferenz zwischen ausgesandtem und empfangenem Signal bestimmt. Da die meisten Systeme auf den Puls Laserscannern basieren, werden nur diese näher erläutert. Hierbei wird die Entfernung zwischen Laserscanner und Objekt aus der entstandenen Laufzeit des Pulses, vom Laserscanner zum Objekt und zurück zum Laserscanner, bestimmt (Abb. 2.1):

$$r = \frac{v \cdot \tau}{2} \quad , \quad (2.1)$$

mit  $r$  als Entfernung zwischen Laserscanner und Objekt,  $v$  als Geschwindigkeit des Laserpulses und  $\tau$  als Laufzeitmessung [Wehr 1999].

Durch unterschiedliche Scanmethoden, wie zum Beispiel dem oszillierenden Spiegel [Wehr 1999], lässt sich jeder Laserpuls so ablenken, dass nicht nur entlang der Flugrichtung, sondern auch quer zur Flugrichtung aufgenommen werden kann (Abb. 2.1) und somit eine größere Fläche erfasst wird. Die dreidimensionale Punktwolke im benötigten Koordinatensystem, zum Beispiel WGS84, kann dann bestimmt werden, wenn die Position und Orientierung des Laserscanners bekannt sind (Abb. 2.2). Für diese Bestimmung wird noch zusätzlich ein Satellitennavigationssystem, meistens GPS, und eine Inertial Measurement Unit (IMU) benötigt [Wehr 1999].




Abb. 2.3: Vergleich diskrete und full-waveform Daten nach [Mallet 2010]

Im Wesentlichen gibt es zwei verschiedene Methoden, um das Echo aufzunehmen. Zum einen die diskrete Echobestimmung und zum anderen das fortgeschrittene Verfahren, die full-waveform Aufnahme. Bei den diskreten Laserscannern lassen sich multiple Echos (first, intermediate und last) pro emittierten Puls aufnehmen. Bei full-waveform Daten wird - im Gegensatz zu der diskreten Echobestimmung - das gesamte reflektierte Signal mit deutlich mehr Abtaststellen aufgenommen (Abb. 2.3).

Das empfangene Signal kann zum Beispiel durch Aufspaltung in die Gaußkomponenten analysiert werden [Wagner 2006]. Erst nach der Analyse der full-waveform Daten können für jedes Echo Beobachtungen wie Amplitude, Echobreite und Echoanzahl aufgestellt werden (Abb. 2.4). Ein Vorteil von full-waveform Daten ist der, dass zur Entfernungsmessung zusätzliche Attribute, also Amplitude, Echobreite und Echoanzahl, zur Verfügung stehen und bei der Charakterisierung der Punkte helfen können [Mallet 2009]. Außerdem lassen sich noch weitere Merkmale aus diesen Beobachtungen aufstellen (siehe Kapitel 3.2).

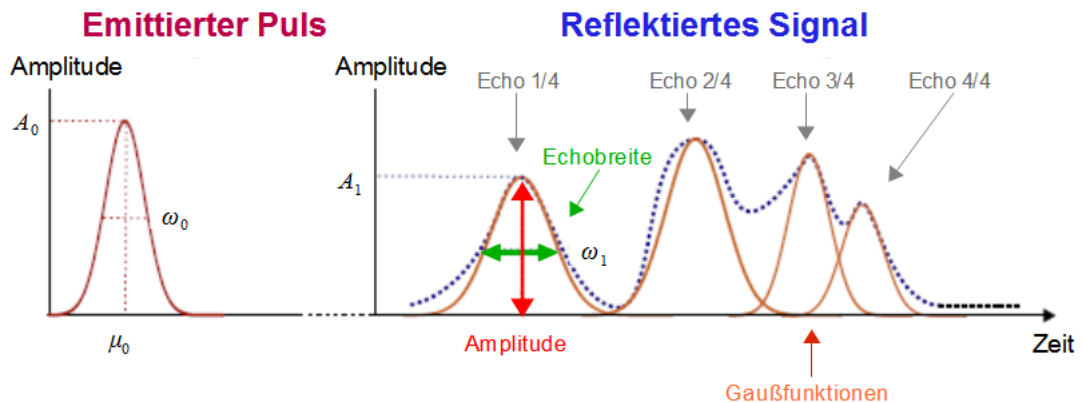


Abb. 2.4: Amplitude, Echobreite, Echoanzahl nach [Mallet 2010]

## 2.2 Aktuelle Klassifikationsverfahren

Ziel einer Klassifikation ist es, die Daten einer Objektklasse zuzuordnen, wobei die Zuordnung der Daten in mehrere definierte Klassen erfolgen kann. Die Daten entsprechen in unserem Fall den Merkmalen der einzelnen Punkte aus der Laserpunktwolke. Diese Merkmale werden aus den Sensordaten abgeleitet und in einem  $m$ -dimensionalen Merkmalsvektor  $\mathbf{x}$  abgespeichert. Klassen kennzeichnen die Einordnung der einzelnen Punkte der Punkt wolke zum Beispiel in die Kategorien *Gebäude*, *Boden*, *Gebüsch* und *Bäume*.

In diesem Abschnitt werden die aktuellen Verfahren zur Klassifikation vorgestellt, die ohne Berücksichtigung von Nachbarschaftsbeziehungen arbeiten. Zunächst werden die linearen Modelle anhand der Diskriminanzfunktion erklärt, mit der Daten in Klassen eingeteilt werden können. Zum Schluss wird das schon seit zwei Jahrzehnten eingesetzte Verfahren der Support Vectors Machines erläutert, das gute Ergebnisse bei der Klassifikation liefert, ohne Kontextwissen einzubeziehen [Gualtieri 1998]. Häufig wird dieses Verfahren aufgrund der guten Ergebnisse als Referenz für den Vergleich mit anderen Methoden eingesetzt. In dieser Arbeit soll dieses Verfahren ebenfalls als Referenz dienen.

### 2.2.1 Lineare Modelle

Zur Klassifikation können lineare Modelle verwendet werden. Lineare Modelle heißen so, weil sich der Merkmalsraum, der durch die Merkmale aufgespannt wird, durch lineare Funktionen und somit durch  $(m-1)$ -dimensionale Hyperebenen trennen lässt. Die Hyperebenen entsprechen Entscheidungsgrenzen, die den Merkmalsraum in Entscheidungsregionen unterteilen. Linear separierbare Daten sind somit Daten, die exakt durch lineare Entscheidungsgrenzen separierbar sind [Bishop 2006].

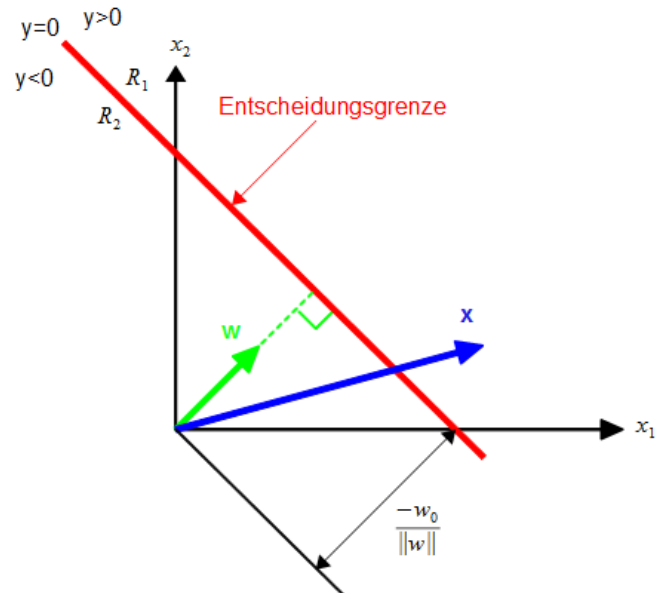


Abb. 2.5: Geometrie der Diskriminanzfunktion im zweidimensionalen Merkmalsraum nach [Bishop 2006]

Die Diskriminanzanalyse ist das einfachste lineare Modell bei der Klassifikation. In diesem Modell wird eine lineare Diskriminanzfunktion bestimmt, die den Merkmalsvektor  $\mathbf{x}$  einer Klasse  $C_i$  zuordnet und somit den Merkmalsraum in Entscheidungsregionen unterteilt. Die einfachste Darstellung einer linearen Diskriminanzfunktion lautet:

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 \quad (2.2)$$

## 2.2 Aktuelle Klassifikationsverfahren

wobei  $y(\mathbf{x})$  die Diskriminanzfunktion beschreibt, mit der die Klassifikation realisiert wird. Durch den Gewichtsvektor  $\mathbf{w}$  wird die Orientierung der Entscheidungsgrenze festgelegt; die Bestimmung erfolgt während des Trainingsprozesses (siehe Kapitel 3.3). Der Bias-Parameter  $w_0$  gibt die Position an, an der sich die Entscheidungsgrenze befindet. Im Zwei-Klassen-Fall bedeutet das, dass der Merkmalsvektor der Klasse  $C_1$  zugeordnet wird, wenn  $y(\mathbf{x}) > 0$  ist, ansonsten zur Klasse  $C_2$  (Abb. 2.5). Die Entscheidungsgrenze liegt genau bei  $y(\mathbf{x}) = 0$  und somit auch die Hyperebene. Durch die Hyperebene wird der Merkmalsraum in zwei Entscheidungsregionen  $R_1$  und  $R_2$  geteilt.

Werden mehr als zwei Klassen verwendet, so können verschiedene Methoden angewendet werden, um die Klassen zu trennen. Eine Methode ist die One-Versus-All Methode. Hierbei werden  $(m-1)$  Klassifizierer (hier: Diskriminanzfunktionen) aufgestellt; jeder der Klassifizierer löst dabei ein Zwei-Klassen-Problem. Es wird nun immer eine Klasse von allen anderen getrennt und mit Hilfe von Widersprüchen die korrekte Klasse ermittelt.

Im Gegensatz dazu benötigt die One-Versus-One Methode eine Anzahl von  $m(m-1)/2$  Klassifizierern. Das ergibt für jedes mögliche Paar von Klassen einen




Abb. 2.6: Feature Space Mapping: Transformation einer Geraden ( $y$ ) im 2D Merkmalsraum in eine Parabel im 3D Merkmalsraum. Die Ebene teilt den 3D Merkmalsraum in zwei Regionen nach [Duda 2001]

## 2.2 Aktuelle Klassifikationsverfahren

---

Klassifizierer. Nach der Klassifikation aller Daten wird diejenige Klasse selektiert, die die meisten Stimmen der verschiedenen Klassifizierer erhält [Bishop 2006].

Da sich aber Merkmale im Merkmalsraum manchmal nicht durch eine lineare Funktion trennen lassen, besteht die Möglichkeit, diese in einen höherdimensionalen Merkmalsraum zu überführen, in dem sie besser linear trennbar sind (Abb. 2.6). Diese Anwendung ist als Feature Space Mapping bekannt. Die Transformation in den anderen Merkmalsraum kann mit einer beliebigen nichtlinearen Funktion  $\Phi(\mathbf{x})$  erfolgen. Der Vorteil besteht darin, dass die Funktion  $y(\Phi(\mathbf{x}))$  trotzdem linear bleibt. Solche Modelle werden generalisierte oder verallgemeinerte lineare Modelle genannt [Duda 2001].

### 2.2.2 Support Vector Machines

Die Support Vector Machines (SVM) gehören zu der überwachten Klassifikation, so dass in jedem Fall Trainingsdaten benötigt werden. Ähnlich wie bei den linearen Modellen, wird bei den linearen SVM eine Hyperebene im höherdimensionalen Merkmalsraum gesucht, die die Klassen linear trennt. Die Gleichung für diese Hyperebene lautet:

$$\varepsilon: \mathbf{w}^T \Phi(\mathbf{x}) + b = 0 \quad (2.3)$$

Die Transformation in einen höherdimensionalen Merkmalsraum, in dem die Klassen linear trennbar sind, wird mit  $\Phi(\mathbf{x})$  beschrieben. Der Vektor  $\mathbf{w}$ , der senkrecht auf der Hyperebene steht, gibt die Orientierung der Hyperebene an und durch  $b$  wird die Verschiebung der Hyperebene realisiert (vgl. Abb. 2.5).

Dabei wird das Maximum Margin Prinzip angewendet. Das bedeutet, dass die Hyperebene so angeordnet wird, dass der Abstand (engl. margin) der Hyperebene zum nächsten Datenpunkt der Trainingsdaten so groß wie möglich ist (Abb. 2.7). Die

## 2.2 Aktuelle Klassifikationsverfahren

Datenpunkte, die der Hyperebene am nächsten liegen, werden als Support Vectors (engl. Stützvektoren) bezeichnet. Der margin wird durch  $2/\|\mathbf{w}\|$  berechnet. Dieser Term muss somit nach dem Maximum Margin Prinzip maximal werden und folglich  $\|\mathbf{w}\|^2$  minimiert werden. Um dieses Problem zu lösen, wird eine Lagrange-Funktion verwendet [Burgess 1998].

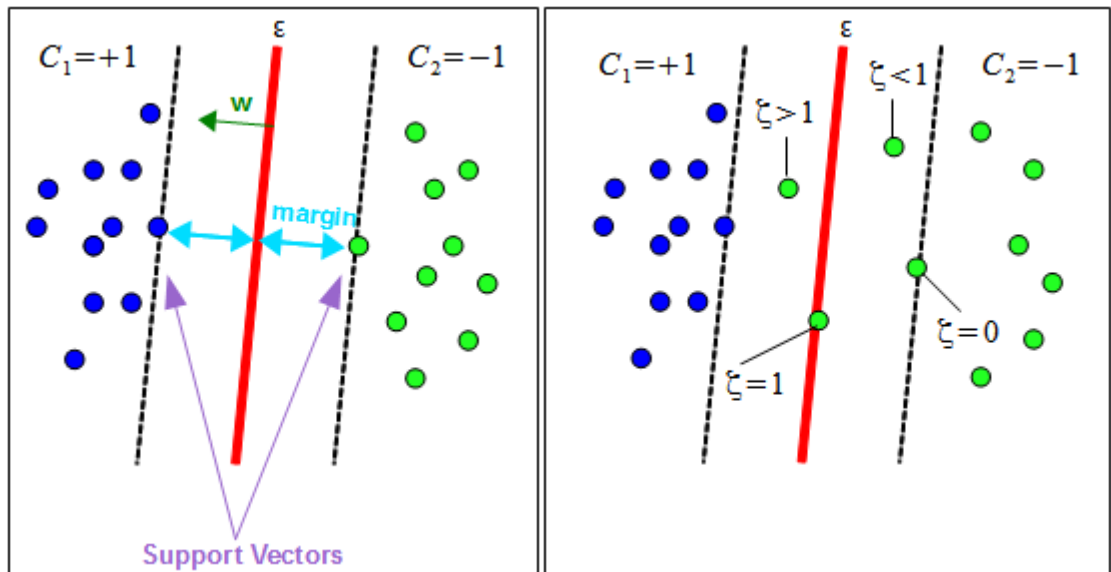


Abb. 2.7: Hyperebene mit Abstand (margin), Klassen und Support Vectors

Abb. 2.8: Darstellung der Schlupfvariablen nach [Rottensteiner 2012]

Wie bei den linearen Modellen schon erwähnt, wird das Feature Space Mapping verwendet, um Datenpunkte zu trennen, die im Merkmalsraum nicht linear trennbar sind. Da die Berechnung dieser Transformation sehr komplex und rechenaufwändig ist, wird der sogenannte Kernel-Trick angewendet. Mit diesem wird die Transformation durch eine Kernel-Funktion substituiert, so dass die Berechnung der Transformationsfunktion nie explizit erfolgen muss [Burgess 1998]. Das Ergebnis nach dem Training ist eine Liste der Support Vectors und der Parameter der Hyperebene ( $b$ ,  $\mathbf{w}$ ), die die beiden Klassen voneinander trennen.

Nach dem Training kann die Klassifikation der Datenpunkte erfolgen. Dabei lässt sich die Klasse für einen Merkmalsvektor  $\mathbf{x}$  bestimmen, indem man das Vorzeichen

## 2.2 Aktuelle Klassifikationsverfahren

---

der Hyperebenengleichung betrachtet. Alle Daten, die ein positives Vorzeichen aufweisen, liegen auf der einen Seite der Hyperebene. Alle Daten mit einem negativen Vorzeichen liegen auf der anderen Seite der Hyperebene (Abb. 2.7).

Das Modell der SVM kann erweitert werden, indem ein zusätzlicher Parameter, die positive Schlupfvariable  $\zeta_i \geq 0$  (engl. slack variable), für jeden Trainingsdatenpunkt eingeführt wird. Diese bewirkt, dass Fehlklassifikationen zugelassen werden können, diese aber bestraft werden. Somit gilt für die Daten im margin oder auf der falschen Seite der Hyperebene:

$$\zeta_i = |C_i - \mathbf{w}^T \Phi(\mathbf{x}_i) + b| \quad (2.4)$$

Wie in Abb. 2.8 zu sehen ist, bedeutet das für Daten an der Grenze des margin oder im Bereich der korrekten Klasse  $C_i$ , dass es keine Bestrafung gibt; also ist  $\zeta_i = 0$ . Daten direkt auf der Hyperebene erhalten eine Bestrafung von  $\zeta_i = 1$ . Eine kleine Bestrafung mit  $\zeta_i < 1$  gibt es für Daten im Rand, die sich aber auf der richtigen Seite der Hyperebene befinden. Für Daten, die sich auf der falschen Seite befinden, wird eine größere Bestrafung mit  $\zeta_i > 1$  angesetzt [Rottensteiner 2012]. Bisher wurden die SVM mit einem Zwei-Klassen-Fall betrachtet. Um ein Mehrklassenproblem lösen zu können, können die schon bereits erwähnten Methoden in Kapitel 2.2.1 auf die SVM übertragen werden.

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

Die probabilistische Klassifikation basiert auf Wahrscheinlichkeiten. Das bedeutet, die einzelnen Punkte aus der Punktwolke werden in die Klasse eingeteilt, die die höchste Wahrscheinlichkeit aufweist. Zu der probabilistischen Klassifikation gehört zum Beispiel die Maximum-Likelihood-Klassifikation. In diesem Kapitel wird jedoch auf die probabilistische Klassifikation mit graphischen Modellen wie die



## 2.3 Probabilistische Klassifikation mit graphischen Modellen

Markov Random Fields und die Conditional Random Fields eingegangen.

Zunächst werden die Grundlagen des Modellierens mit Hilfe von Wahrscheinlichkeiten und die Herleitung des Bayes Theorems erläutert. Danach wird erklärt, wie mit Hilfe von Graphen Informationen repräsentiert und ihr Kontext modelliert werden kann. Durch Graphen kann eine Verbindung zum probabilistischen Modellieren geschaffen werden. Zum Schluss werden dann ausgewählte probabilistische Verfahren zur Klassifikation, also die Markov Random Fields und die Conditional Random Fields, vorgestellt.

### 2.3.1 Probabilistische Theorie

Für die nachfolgenden Erläuterungen werden die Klassen mit  $C$  und die Merkmale mit  $\mathbf{x}$  gekennzeichnet. Die zwei grundlegenden Formeln in der probabilistischen Theorie sind die Produkt- und Summenregel (Formel 2.5-2.7) [Bishop 2006]. Aus ihnen lässt sich auch das Theorem von Bayes herleiten.

$$\text{Produktregel: } p(\mathbf{x}, C) = p(C|\mathbf{x}) \cdot p(\mathbf{x}) \quad (2.5)$$

$$\text{Summenregel: } p(\mathbf{x}) = \sum_C p(\mathbf{x}, C) \quad (2.6)$$

$$\text{und ebenso } p(C, \mathbf{x}) = p(\mathbf{x}|C) \cdot p(C) \quad (2.7)$$

Dabei beschreibt  $p(\mathbf{x})$  die Wahrscheinlichkeit für das Eintreten der Daten  $\mathbf{x}$ , entsprechend ist  $p(C)$  die Wahrscheinlichkeit für das Eintreten der Klasse  $C$ .  $p(\mathbf{x}, C)$  ist die Verbundwahrscheinlichkeit und entspricht der Wahrscheinlichkeit, dass  $\mathbf{x}$  und  $C$  gemeinsam auftreten. Die bedingte Wahrscheinlichkeit  $p(C|\mathbf{x})$  beschreibt die Wahrscheinlichkeit, dass das Ereignis  $C$  wahr ist, unter der Bedingung, dass das Eintreten des Ereignisses  $\mathbf{x}$  bereits bekannt ist. Aus der Symmetrieeigenschaft  $p(\mathbf{x}, C) = p(C, \mathbf{x})$  und der Produktregel lässt sich das Theorem von Bayes (2.8) aufstellen [Bishop 2006]:

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

---

$$\text{Theorem von Bayes: } p(C|\mathbf{x}) = \frac{p(\mathbf{x}|C) \cdot p(C)}{p(\mathbf{x})} \quad (2.8)$$

Ziel der Klassifikation ist es, die Punkte der Punktwolke mit Hilfe ihrer Merkmale in vorgegebene Klassen einzuordnen. Dabei kann die Klasse so bestimmt werden, dass die bedingte Wahrscheinlichkeit für  $C$  bei gegebenen  $\mathbf{x}$  maximal wird. Diese bedingte Wahrscheinlichkeit wird als a posteriori Wahrscheinlichkeit  $p(C|\mathbf{x})$  bezeichnet. Mit Hilfe des Theorems von Bayes lässt sich die a posteriori Wahrscheinlichkeit beschreiben.

Dabei besteht die Gleichung des Theorem von Bayes aus folgenden Termen: Die bedingte Wahrscheinlichkeit  $p(\mathbf{x}|C)$  wird auch Likelihood genannt. Wie schon bereits erwähnt, ist die bedingte Wahrscheinlichkeit die Wahrscheinlichkeit für das Auftreten der Daten  $\mathbf{x}$  beim Vorliegen der Klasse  $C$ . Mit Hilfe von Trainingsdaten für jede einzelne Klasse können die Parameter für die Likelihood bestimmt werden.  $p(C)$ , auch als a priori Wahrscheinlichkeit bekannt, kann zum Beispiel als Gleichverteilung angenommen werden, wenn keinerlei Informationen über die Wahrscheinlichkeitsverteilung der Klassen vorliegen [Rottensteiner 2012]. Die Wahrscheinlichkeit für die Daten  $p(\mathbf{x})$  ist nichts anderes als eine Normalisierungskonstante, damit  $p(C|\mathbf{x})$  als Wahrscheinlichkeit gedeutet werden kann. Dabei nimmt das Ergebnis die Werte zwischen 0 und 1 an.

### 2.3.2 Graphische Modelle zur Modellierung von Kontext

Ein Graph  $G=(V, E)$  ist aus einer endlichen Menge von Knoten  $V$  (vertices) und Kanten  $E$  (edges) aufgebaut. Zwei Knoten können dabei durch eine Kante verbunden werden.

Graphische Modelle basieren auf Graphen, entsprechen aber probabilistischen Modellen [Wegner 2011]. Für uns kann der Graph dazu genutzt werden, um die ALS

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

Punktvolke zu strukturieren und eine Verbindung zum probabilistischen Modellieren zu schaffen. Allgemein kann man sagen, dass jeder Knoten einer Zufallsvariablen entspricht. In unserem Fall wird jeder einzelne Laserpunkt aus der Punktvolke durch einen Knoten repräsentiert; die Kanten stellen die probabilistische Beziehung zwischen diesen Punkten her.

Durch die Graphen können Informationen und ihr Kontext dargestellt werden; sie dienen der Modellbildung [Bishop 2006]. Durch Kontext kann beeinflusst werden, dass die Einordnung eines Punktes aus der Punktvolke in eine bestimmte Klasse wahrscheinlicher ist als in eine andere Klasse. Das bedeutet, dass jeder einzelne Punkt aus der Punktvolke nicht nur anhand seiner Merkmale klassifiziert wird, sondern weitere Punkte in seiner Umgebung in den Entscheidungsprozess mit einbezogen werden können. Beispielsweise kann modelliert werden, dass die Wahrscheinlichkeit für einen Punkt für die Klasse *Gebäude* höher ist, obwohl die Merkmale zur Zuordnung *Wasser* sprechen, weil die anderen Punkte in der Umgebung ebenfalls zur Klasse *Gebäude* gehören. Durch die Einbeziehung von Kontextwissen können bessere Ergebnisse bei der Klassifikation erreicht werden [Wegner 2011]. Die hier vorgestellten probabilistischen Verfahren Markov Random Fields und Conditional Random Fields nutzen dieses Kontextwissen aus. Im Gegensatz dazu wird bei den Verfahren ohne Kontextwissen, wie zum Beispiel die Support Vector Machines, jeder einzelne Punkt für sich selbst betrachtet und nur anhand seiner Merkmale einer Klasse zugeordnet.




Abb. 2.9: links: Ungerichteter Graph, Mitte: Gerichteter Graph, rechts: Faktorgraph

Außerdem kann man zwischen gerichteten und ungerichteten graphischen Modellen

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

---

unterscheiden. Das gerichtete graphische Modell (directed), auch als Bayessches Netz bekannt, weist dabei eine bestimmte Richtung der Kante auf (Abb. 2.9). Dieses gerichtete graphische Modell soll dazu dienen, kausale Beziehungen zwischen den Knoten zu beschreiben. Kausalität bedeutet nichts anderes, als dass bestimmte Knoten als Ursachen ( $a$  und  $b$ ) einer Beobachtung ( $c$ ) entsprechen. Die Richtung steht demzufolge für den Einfluss der Zufallsvariablen auf ihre Nachfolgerknoten, somit haben in der Abb. 2.9 die Zufallsvariablen  $a$  und  $b$  einen Einfluss auf die Zufallsvariable  $c$ . Das bedeutet, dass die Zufallsvariablen  $a$  und  $b$  voneinander unabhängig sind, jedoch nicht bedingt unabhängig bezüglich  $c$ . Die Verbundwahrscheinlichkeit für das Beispiel in der Abbildung kann wie folgt aufgestellt werden:

$$p(a, b, c) = p(a) p(b) p(c|a, b) \quad (2.9)$$

Weist die Kante keine Richtung auf (Abb. 2.9), so spricht man von einem ungerichteten graphischen Modell (undirected), auch als Random Field bekannt [Bishop 2006].

Eine weitere Repräsentation ist der Faktorgraph. Gerichtete und ungerichtete Graphen können in einen Faktorgraph (Abb. 2.9) umgewandelt werden [Kschischang 2001], in dem jede Kante ein Gewicht erhält.

In ungerichteten Graphen sind Cliques enthalten. Diese entstehen, wenn zwei Knoten durch eine Kante miteinander verbunden sind. Dabei können mehrere Cliques in einem Graphen enthalten sein und ein Knoten kann zu mehreren Cliques gehören. Eine spezielle Form der Cliques sind die maximalen Cliques, diese entsprechen der größtmöglichen Clique [Bishop 2006]. Die größtmögliche Clique enthält einfach die größte Anzahl an Kanten mit denen die Knoten verbunden sind.

Zusammenfassend lässt sich sagen, dass die Markov Random Fields und Conditional Random Fields zu den erläuterten probabilistischen graphischen Modellen gehören.

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

Diese Klassifikationsverfahren benötigen einen Graph, welcher die Daten repräsentiert.

### 2.3.3 Markov Random Fields

Die Markov Random Fields (MRF) gehören zu den ungerichteten graphischen Modellen. Sie sind generative Modelle, das bedeutet, dass die a posteriori Wahrscheinlichkeit  $p(C|\mathbf{x})$  mit Hilfe des Bayes Theorems bestimmt wird. Dazu findet eine Modellierung der bedingten Wahrscheinlichkeit  $p(\mathbf{x}|C)$  sowie der a priori Wahrscheinlichkeit  $p(C)$  statt. Die MRF lassen sich so deuten, dass die Klassen  $C$  benachbarter Punkte über Kanten verbunden (Abb. 2.10), aber die Daten  $\mathbf{x}_i$  benachbarter Punkte bedingt unabhängig voneinander sind [Rottensteiner 2012]. Lokaler Kontext wird somit durch den Vergleich von Klassenlabels erlernt.




Abb. 2.10: Graphenstruktur der MRF nach [Bishop 2006]

Das Ziel der MRF ist es, die Klasse mit der größten Wahrscheinlichkeit bei gegebenen Daten zu identifizieren. Um das zu erreichen, wird eine Energiefunktion verwendet, mit der gleichzeitig die Beziehung in der Abb. 2.10 dargestellt wird. Dabei kann die Energiefunktion aus zwei Anteilen (Gleichung (2.10)) zusammengefasst werden. Der erste Term  $A_i(C_i, \mathbf{x}_i)$  wird Assoziationspotential

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

genannt. Dieser verknüpft die Daten mit den Klassen. Der zweite Term  $\psi_{ij}(C_i, C_j)$  wird auch paarweises Cliquespotential genannt und modelliert den Kontext zwischen den Klassen. Im übrigen beschreiben diese beiden Anteile die zwei verschiedenen Cliques in den MRF. Zum einen die Cliques, die zwischen den Daten und Klassen und zum anderen die Cliques, die zwischen den unterschiedlichen Klassen entstehen.

$$P(C|\mathbf{x}) = \frac{1}{Z(\mathbf{x})} \cdot \exp\left(\sum_{i \in S} A_i(C_i, \mathbf{x}_i) + \sum_{i \in S} \sum_{j \in N_i} \psi_{ij}(C_i, C_j)\right) \quad (2.10)$$

$\mathbf{x}_i$  beschreibt die Daten, die im Knoten  $i$  beobachtet werden. Die gesamte Anzahl aller Knoten im Graphen wird mit  $S$  gekennzeichnet.  $N_i$  entspricht hingegen der Anzahl der Knoten in der Nachbarschaft von  $i$ , die mit dem Knoten  $j$  verglichen werden [Kumar 2006].

In dieser Gleichung (2.10) sieht man die Ähnlichkeit zu dem Theorem von Bayes (vgl. Gleichung (2.8)).  $Z(\mathbf{x})$ , die Partitionsfunktion, entspricht der Normalisierungskonstanten, die die Potentiale in Wahrscheinlichkeiten umwandelt. Der Anteil  $A_i(C_i, \mathbf{x}_i)$  entspricht der Likelihoodfunktion und in  $\psi_{ij}(C_i, C_j)$  ist die a priori Wahrscheinlichkeit enthalten.

Um das Assoziationspotential zu modellieren, also die Verknüpfung der Daten mit den Klassen zu schaffen, können beliebige Klassifikatoren verwendet werden. Die Modellierung kann durch die sogenannte Log Likelihood  $A_i(C_i, \mathbf{x}_i) = \log P_i(\mathbf{x}_i|C_i)$  erfolgen, wobei  $P_i(\cdot)$  zum Beispiel proportional zum Ergebnis verallgemeinerter linearer Modelle ist [Kumar 2006].

Die Modellbildung für das paarweise Cliquespotential kann mit verschiedenen Modellen realisiert werden. An dieser Stelle werden drei Modelle vorgestellt.

Für das Multi-Klassen-Problem wird meist für die MRF als Standardmodell das Potts-Modell verwendet. Beim Potts-Modell gilt für das paarweise Cliquespotential

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

$\psi_{ij}(C_i, C_j) = \nu \cdot \delta(C_i = C_j)$ . Hierbei wird die Funktion  $\delta(C_i = C_j)$  nur bei gleichen Klassenkombinationen (z.B. *Gebäude* und *Gebäude*) zu 1 und bei unterschiedlichen Klassen (z.B. *Gebäude* und *Boden*) zu 0. Mit dem Gewichtsvektor  $\nu$  wird dann für alle gleichen Klassenkombinationen ein konstantes Gewicht pro Merkmal angelernt.

Ein weiteres Modell für das paarweise Cliquespotential besitzt eine ähnliche Funktion  $\psi_{ij}(C_i, C_j) = \nu_i \cdot \delta(C_i = C_j)$  und wird in dieser Arbeit als erweitertes Potts-Modell bezeichnet. Für diesen Fall werden für alle gleichen Klassenkombinationen unterschiedliche Gewichte  $\nu_i$  angelernt. Durch die Gewichte  $\nu$  bzw.  $\nu_i$  wird beeinflusst, dass der gesamte Term  $\nu \cdot \delta(C_i = C_j)$  bzw.  $\nu_i \cdot \delta(C_i = C_j)$  die a posteriori Wahrscheinlichkeit im Falle identischer Klassen erhöht. Bei ungleichen Klassen wird die a posteriori Wahrscheinlichkeit vermindert.

Das dritte Modell wird in dieser Arbeit als Modell des vollen Potentials bezeichnet. Durch die Funktion  $\psi_{ij}(C_i, C_j) = \nu_{ij}$  werden für alle möglichen Klassenkombinationen, also nicht nur im Falle gleicher Klassen, Gewichte  $\nu_{ij}$  angelernt. Welches der drei Modelle für das Multi-Klassen-Problem die besseren Eigenschaften aufweist, wird in Kapitel 4.4 untersucht.

Das Potts-Modell und das erweiterte Potts-Modell führen zu einer geglätteten Klassifikation, weil modelliert wird, dass die Wahrscheinlichkeit geringer ist, dass sich Klassen benachbarter Punkte unterscheiden. Der Grad der Glättung wird dabei durch den Parameter  $\nu$  bzw.  $\nu_i$  beeinflusst. Ein weiteres Problem besteht darin, dass nur die Klassenlabel der direkten Nachbarn aufgrund der zugrunde liegenden strengen Annahme der bedingten Unabhängigkeit verglichen werden können und nicht alle in der Umgebung liegenden Punkte. Eine zusätzliche Einschränkung ist, dass mit diesem Modell keine Daten anderer Knoten bei der Klassifikation berücksichtigt werden können, da es nur eine Beziehung zwischen den Daten und der dazugehörigen Klasse gibt (vgl. Abb. 2.10) [Wegner 2011]. Daher werden die Conditional Random Fields eingeführt, denen weniger strikte Bedingungen zugrunde liegen.

### 2.3.4 Conditional Random Fields

Die Conditional Random Fields (CRF) können durch einen Faktorgraphen (vgl. Abb. 2.9) dargestellt werden. Im Gegensatz zu den MRF werden die CRF den diskriminativen Modellen zugeordnet, dabei kann die a posteriori Wahrscheinlichkeit direkt modelliert werden [Kumar 2006]:

$$P(C|\mathbf{x}) = \frac{1}{Z(\mathbf{x})} \cdot \exp\left(\sum_{i \in S} A_i(C_i, \mathbf{x}) + \sum_{i \in S} \sum_{j \in N_i} I_{ij}(C_i, C_j, \mathbf{x})\right) \quad (2.11)$$

Auch hier besteht die Energiefunktion aus zwei Anteilen: dem Assoziationspotential  $A_i(C_i, \mathbf{x})$  und dem paarweisen Interaktionspotential  $I_{ij}(C_i, C_j, \mathbf{x})$ . Der Unterschied zu den MRF besteht darin, dass zum einen das Assoziationspotential eine Funktion aller möglichen Daten  $\mathbf{x}$  ist. Das bedeutet im Gegensatz zu den MRF, dass der Knoten  $i$  nicht nur von den Daten  $x_i$ , die in diesem Knoten beobachtet werden, abhängig ist, sondern von allen möglichen Daten  $\mathbf{x}$  im Graphen. Zum anderen wird durch das paarweise Interaktionspotential erlernt, dass der globale Kontext von Klassen und Daten  $\mathbf{x}$  verglichen wird und nicht, wie bei den MRF, auf die lokale Nachbarschaft beschränkt ist [Kumar 2006]. Diese beiden Unterschiede zu den MRF sind auch in der Abb. 2.11 zu erkennen. Es gibt nun auch Kanten zwischen jeder Klasse  $C_i$  und allen anderen Daten  $\mathbf{x}$  im Graphen. Durch diese Eigenschaften




Abb. 2.11: Graphenstruktur der CRF nach [Bishop 2006]



## 2.3 Probabilistische Klassifikation mit graphischen Modellen

der CRF kann der Glättungseffekt, der bei den MRF auftritt, ausgeglichen werden [Rottensteiner 2012].

Die Modellierung des Assoziationspotentials und des paarweisen Interaktionspotentials kann auf verschiedene Arten erfolgen. Beispielsweise können die SVM zur Modellierung herangezogen werden oder auch verallgemeinerte lineare Modelle. Die in dieser Arbeit verwendete Modellierung für beide Potentiale werden durch die Log Likelihood modelliert und basiert auf der Verwendung von verallgemeinerten linearen Modellen (vgl. Kapitel 2.2.1), somit gilt [Niemeyer 2011]:

$$A_i(C_i, \mathbf{x}) = \mathbf{w}^T \Phi(\mathbf{h}_i(\mathbf{x})) \quad (2.12)$$

$$I_{ij}(C_i, C_j, \mathbf{x}) = \mathbf{v}^T \Phi(\boldsymbol{\mu}_{ij}(\mathbf{x})) \quad (2.13)$$

Der Merkmalsvektor  $\mathbf{h}_i(\mathbf{x})$  des Knotens  $i$  wird aus den Daten  $\mathbf{x}$  bestimmt und kann somit die Daten aller Knoten enthalten. Der Vektor  $\mathbf{w}^T$  beinhaltet die Gewichte der Merkmale von  $\mathbf{h}_i(\mathbf{x})$ . Hohe Gewichte erhalten diejenigen Merkmale, die helfen, die Objektklassen voneinander zu trennen. Niedrige Gewichte werden vergeben, wenn die Merkmale bei der Trennung einen geringen Anteil beitragen. Pro Klasse wird solch ein Vektor  $\mathbf{w}^T$  im Trainingsprozess (siehe Kapitel 3.3) bestimmt.

Genau wie bei dem paarweisen Cliquespotential (vgl. Kapitel 2.3.3) können für das Interaktionspotential die selben Modelle verwendet werden. Mit einem konstanten Gewicht pro Merkmal  $\mathbf{v}^T$  für gleiche Klassenkombinationen wird das Potts-Modell für das Interaktionspotential genutzt. Für das erweiterte Potts-Modell muss das konstante Gewicht  $\mathbf{v}^T$  durch die unterschiedlichen Gewichte  $\mathbf{v}_i^T$  ersetzt werden, die ebenfalls nur für gleiche Klassenkombinationen bestimmt werden. Möchte man das Modell des vollen Potentials verwenden, so muss  $\mathbf{v}^T$  mit den unterschiedlichen Gewichten  $\mathbf{v}_{ij}^T$  für jede beliebige Klassenkombination ersetzt werden. Die

## 2.3 Probabilistische Klassifikation mit graphischen Modellen

---

Bestimmung der Gewichte je nach Modell erfolgt ebenfalls während des Trainingsprozesses (Kapitel 3.3). Auch an dieser Stelle wird überprüft, welche der drei Modelle nützlicher bei der Klassifikation sind (Kapitel 4.4).

Die Interaktionsmerkmalsvektoren  $\mu_{ij}(\mathbf{x})$  werden bestimmt, indem man die Differenz zwischen den Merkmalsvektoren der Knoten  $\mu_{ij}(\mathbf{x}) = |\mathbf{h}_i(\mathbf{x}) - \mathbf{h}_j(\mathbf{x})|$  bildet. Dabei gibt es pro Kante einen Interaktionsmerkmalsvektor, der bestimmt werden muss.

Im übrigen führt auch das paarweise Interaktionspotential, wie bei den MRF, zu einer geglätteten Klassifikation. Diese Glättung ist aber vom Interaktionsmerkmalsvektor abhängig. Wenn die Daten homogen sind, also der Interaktionsmerkmalsvektor einen niedrigen Wert annimmt, so ist die Glättung groß. Je ungleicher die Daten sind, also der Interaktionsmerkmalsvektor einen höheren Wert annimmt, desto mehr wird die Glättung unterdrückt.

## 3 Methode

In diesem Abschnitt wird zunächst die Definition des Graphen (Kapitel 3.1) für die full-waveform Laserpunktwolke erläutert. In Kapitel 3.2 werden die zu verwendenden Merkmale ausführlich beschrieben. Anschließend wird in Kapitel 3.3 erläutert, wie der Trainingsprozess und die Inferenz für die MRF und CRF funktionieren.

### 3.1 Definition des Graphen

Die Definition des Graphen einer Punktvolke ist komplexer als die eines Bildes. Die Punkte in einer Punktvolke haben eine unregelmäßige Anordnung im dreidimensionalen Raum und zunächst keine vordefinierte Anzahl an Nachbarn, wie das der Fall bei einem Bild ist.

Zur Definition eines Graphen einer Punktvolke gibt es verschiedene Ansätze. Zum Beispiel lassen sich die Nachbarn für einen Graphen mit den  $k$ -Nächste-Nachbarn (kNN), durch eine sphärische oder zylindrische Umgebung ermitteln. Bei dem Ansatz der kNN werden durch Vorgabe der Anzahl an Nachbarn, z.B.  $k=3$ , die drei nächsten Punkte gesucht und mit ihnen der Graph aufgebaut, so dass jeder Knoten mit drei Kanten verbunden ist. Der Ansatz mit der zylindrischen Umgebung basiert darauf, dass um jeden Punkt ein vertikaler Zylinder mit einem manuell bestimmbar Radius aufgespannt und dieser mit den Punkten, die sich in diesem Zylinder befinden, verbunden wird (Abb. 3.1). Die Punkte im Zylinder entsprechen den Nachbarn.




Abb. 3.1:  
Graphenstruktur einer  
Punktvolke mit  
zylindrischer  
Umgebung nach  
[Niemeyer 2011]

Zur Speicherung der Punkte wird ein zweidimensionaler kd-Baum verwendet.

Ähnlich wie der Ansatz mit der zylindrischen Umgebung funktioniert auch der Ansatz mit der sphärischen Umgebung, nur dass anstatt eines Zylinders eine Kugel mit entsprechendem Radius aufgespannt wird. Der zylindrische Ansatz ist jedoch besser geeignet, da Punkte an Baumkronen und Dachkanten trotzdem noch Verbindungen zu Punkten am Boden aufweisen können und somit ein besseres Ergebnis bei der Klassifikation erreicht werden kann [Niemeyer 2011]. In Kapitel 4.3 wird untersucht, ob der Ansatz der kNN oder der Ansatz mit der zylindrischen Umgebung bessere Ergebnisse liefert.

### **3.2 Merkmale für Knoten und Kanten**

Im Allgemeinen lassen sich die Merkmale der Knoten in mehrere Kategorien einteilen: Merkmale aus den full-waveform Daten, echobasierte und geometrische Merkmale. Wobei die geometrischen Merkmale nochmals in höhen-, eigenwert- und ebenenbasierte Merkmale unterteilt werden können. Die echobasierten und geometrischen Merkmale werden mit Hilfe einer volumetrischen Umgebung, einem vertikalen Zylinder oder Kugel, die den aktuellen Punkt umgibt, bestimmt [Cheheta 2009].

Zu den aus full-waveform Daten abgeleiteten Merkmalen gehören (vgl. Kapitel 2.1):

- $A_i$  Amplitude: Häufig wird die Amplitude auch als Intensität bezeichnet und gibt daher Informationen über die Reflektivität der Objekte an. Hohe Werte für die Amplitude sind auf Gebäudedächern, Kies und Kraftfahrzeugen, niedrige Werte hingegen auf Asphalt und Teerstraßen zu erwarten. Bei Vegetation ist auch ein niedriger Wert aufzufinden, da das Signal durch die unterschiedlichen Schichten der Vegetation abgeschwächt wird.
- $w_i$  Echobreite: Meistens sind für Vegetation höhere Werte für die Echobreite zu bestimmen, da der Puls durch die Vegetation aufgeweitet wird.

## 3.2 Merkmale für Knoten und Kanten

---

Aber auch schräge Flächen, wie geneigte Dächer, können zu einer Aufweitung des Pulses führen. Niedrigere Werte sind meistens auf dem Boden oder auf Gebäuden zu finden. Normalerweise ist die Echobreite ein nützliches Merkmal. Für das in dieser Arbeit verwendete Testgebiet steht jedoch die Echobreite nicht zur Verfügung.

Bei den echobasierten Merkmalen unterscheidet man zwischen:

- $N$  Echoanzahl: Die Anzahl der Echos wird aus der empfangenen Wellenform abgeleitet. Für Vegetation und Gebäudefassaden steigt die Anzahl der Echos. Trifft die gesamte Energie des Pulses auf einen Punkt, so gibt es nur ein Echo.
- $n$  Echonummer: Zeigt die aktuelle Nummer der verschiedenen Echos.
- $N_e$  Echoratio: Dieser Wert wird ermittelt, indem man die Echonummer  $n$  durch die Echoanzahl  $N$  dividiert. Durch dieses Merkmal wird besonders die Vegetation erkennbar, da hier multiple Reflexionen auftreten.
- $PDR$  Point Density Ratio: Hierbei wird die Anzahl der Punkte in der Kugel durch die Anzahl der Punkte im Zylinder dividiert. Dabei ist der Radius beider Elemente gleich (1,25m).

Bei den höhenbasierten Merkmalen lässt sich unterscheiden in:

- $\Delta z_{fl}$ : Beschreibt die Höhendifferenz zwischen dem ersten (first) und letzten (last) Echo. Diese Höhendifferenz hilft, zwischen Punkten auf Gebäudedächern und Punkten auf dem Boden zu unterscheiden. Hohe Differenzen sind meist an Gebäudekanten und Vegetation zu finden.
- $\sigma_z^2$  Höhenvarianz: Zeigt Streuung der Höhe und ist besonders bei Vegetation hoch.
- $Z$  Höhe: Weiterhin wird die Höhe als Merkmale für das Testgebiet genutzt.

Zunächst kann nach [Gross 2006] die Kovarianzmatrix für jeden Punkt im Volumen einer Kugel mit einem festgelegten Radius (hier 1,25m) bestimmt werden. Aus dieser

## 3.2 Merkmale für Knoten und Kanten

lassen sich die Eigenwerte aufstellen. Nun ist es möglich, mit den eigenwertbasierten Merkmalen Ebenen, Kanten, Ecken, Linien und Volumina zu unterscheiden. Zu den eigenwertbasierten Merkmalen gehören:

- $\lambda_1, \lambda_2, \lambda_3$ : Die Eigenwerte mit  $\lambda_1 \geq \lambda_2 \geq \lambda_3$  und die Summe der Eigenwerte. Besonders  $\lambda_1$  zeigt einen niedrigen Wert für Punkte in einer Ebene und hohe Werte für Punkte, sie sich nicht in einer Ebene befinden.
- $A_\lambda, P_\lambda, S_\lambda, L_\lambda, O_\lambda, E_\lambda, V_\lambda$ : Die weiteren eigenwertbasierten Merkmale sind die Anisotropie, Planarität, Sphärizität, Linearität, Omnivarianz, Eigenentropie und das Verhältnis aus dem ersten und dritten Eigenwert. Diese werden nach [Gross 2006] wie folgt bestimmt:

$$A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1}, \quad P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1}, \quad S_\lambda = \frac{\lambda_3}{\lambda_1}, \quad L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1}, \quad O_\lambda = \sqrt[3]{\lambda_1 \lambda_2 \lambda_3},$$

$$E_\lambda = -\ln(\lambda_1)^{\lambda_1} - \ln(\lambda_2)^{\lambda_2} - \ln(\lambda_3)^{\lambda_3}, \quad V_\lambda = \frac{\lambda_1}{\lambda_3}$$

Für die lokal ebenenbasierten Merkmale wird eine lokale Ebene  $\Pi_p$  durch alle Punkte in einer Kugel mit einem festgelegten Radius (hier 1,25m) geschätzt. Die Bestimmung erfolgt mit dem robusten M-Schätzer mit der  $L_{1,2}$  Norm nach [Xu 1996]. Somit können folgende ebenenbasierte Merkmale bestimmt werden:

- $N_z$ : Ist der Neigungswinkel der lokalen Ebene  $\Pi_p$  in der Kugel. Durch dieses Merkmal kann Boden von anderen Objekten besonders unterschieden werden.
- $\sigma_{N_z}^2$ : Ist die dazugehörige Varianz des Neigungswinkels der lokalen Ebene. Hiermit können Punkte auf ebenen Flächen von verteilten Punkten wie Vegetation getrennt werden. Dieser Wert wird somit für Dächer und Boden klein und bei Vegetation hoch sein.
- $R_\pi$ : Die Residuen der lokalen Ebene werden in der Kugel wie folgt bestimmt:

$$R_\pi = \sum_{i \in V_p} \frac{(d_i)^l}{l} \text{ mit } l=1,2 \text{ und } d_i \text{ Abstand zwischen Ebene und aktuellem Punkt}$$

Zusätzlich wird eine Normalisierung mit der Standardnormalverteilung der Merkmale durchgeführt, um zu erreichen, dass alle Merkmale im gleichen Wertebereich liegen. Anschließend wird mit den normalisierten Merkmalen eine Hauptkomponentenanalyse durchgeführt, da die Merkmale häufig miteinander korrelieren. Damit wird erreicht, dass der wichtige Informationsgehalt mit einer geringeren Anzahl an Merkmalen dargestellt wird.

Für jeden Punkt aus der dreidimensionalen Punktwolke werden diese Merkmale bestimmt. Bei den Verfahren MRF und CRF werden dann für jeden Knoten die Merkmale im Merkmalsvektor  $\mathbf{h}_i(\mathbf{x})$  abgespeichert. Außerdem enthält jeder der Merkmalsvektor beider Verfahren einen Bias-Parameter, der den Wert 1 besitzt [siehe Bishop 2006].

Bei den CRF können noch zusätzlich Merkmale für die Kanten aufgestellt werden. Diese werden, wie in Kapitel 2.3.4 bereits erwähnt, aus der Differenz zweier benachbarter Merkmalsvektoren aufgestellt und als Interaktionsmerkmalsvektoren  $\boldsymbol{\mu}_{ij}(\mathbf{x})$  bezeichnet.

### **3.3 Training und Inferenz**

Für das Training und die Inferenz können aufgrund von Zyklen in den Graphen der MRF und CRF nur Approximationen verwendet werden.

Im Trainingsprozess werden die unterschiedlichen Parameter der MRF und CRF angelemt. Für die MRF sind es zum einen die Parameter der Assoziationspotentiale,

also die Gewichte  $\mathbf{w}^T$  für die verallgemeinerten linearen Modelle. Zum anderen die Parameter der paarweisen Cliquespotentiale, also je nach angewendetem Modell, der Gewichtsvektor  $\mathbf{v}^T$  für das Potts-Modell oder die Gewichtsvektoren  $\mathbf{v}_i^T$  bzw.  $\mathbf{v}_{ij}^T$  für das erweiterte Modell bzw. das Modell des vollen Potentials.

Bei den CRF werden die Parameter der Assoziationspotentiale und der paarweisen Interaktionspotentiale, also die Gewichte der Merkmale  $\mathbf{w}^T$  und je nach Modell der Gewichtsvektor  $\mathbf{v}^T$  (Potts-Modell) oder  $\mathbf{v}_i^T$  (erweiterte Potts-Modell) bzw.  $\mathbf{v}_{ij}^T$  (Modell des vollen Potentials) angelernt.

Diese Parameter lassen sich jeweils für die MRF und CRF in einem Parametervektor  $\boldsymbol{\theta}$  zusammenfassen. Für das Anlernen der Parameter wird eine manuell klassifizierte Punktvolke  $\mathbf{X}_{ref}$  mit den Klassen  $\mathbf{C}_{ref}$  benötigt. Nun kann die Bestimmung der Parameter erfolgen, indem die Funktion  $f = -\log P(\boldsymbol{\theta} | \mathbf{X}_{ref}, \mathbf{C}_{ref})$  minimiert wird. Da die Bestimmung des Parametervektors  $\boldsymbol{\theta}$  ein nichtlineares Optimierungsproblem ist, wird zur Lösung die quasi-newtonsche Optimierungsmethode Limited Memory Broyden-Fletcher-Goldfarb-Shanno (L-BFGS) angewendet. Mit dieser wird die oben genannte Funktion optimiert, deren Gradient und die dazugehörige Partitionsfunktion in jedem Iterationsschritt bestimmt. Die Optimierungsmethode L-BFGS wird noch mit dem Algorithmus Loopy Belief Propagation (LBP) [Frey 1998] zur Inferenz wie in [Vishwanathan 2006] gekoppelt. Im Trainingsprozess wird die Berechnung der Inferenz dazu benötigt, um den Gradienten zu erhalten.

LBP ist ein Algorithmus zur Nachrichtenübertragung (engl. message passing) zwischen Knoten für Graphen, die Zyklen enthalten. Da bei Graphen mit Zyklen theoretisch die Nachrichten zwischen den Knoten endlos weitergereicht werden, wird ein Konvergenzkriterium eingeführt; somit ist dieser Algorithmus eine Approximation. Obwohl es keine Garantie zur Konvergenz zum globalen Minimum gibt, werden trotzdem meistens gute Ergebnisse erzielt [Vishwanathan 2006].

Weiterhin wird die Inferenz benötigt, um die a posteriori Wahrscheinlichkeiten für die Testdaten zu generieren. Die Inferenz wird ebenfalls mit dem Algorithmus LBP bestimmt. Dabei wird für jeden Knoten im Graphen und somit für jeden Punkt aus



der Punktwolke mit der Inferenz je eine a posteriori Wahrscheinlichkeit pro Klasse ermittelt. Das bedeutet, dass bei vier Klassen auch vier verschiedene a posteriori Wahrscheinlichkeiten entstehen. Mit dem Maximum-A-Posteriori-Schätzer (MAP) wird dann diejenige Klasse dem Punkt zugeordnet, die die größte Wahrscheinlichkeit enthält. Das Ergebnis der Inferenz ist somit die wahrscheinlichste Klasse für einen Punkt.

## 4 Experimente

Im folgenden Kapitel werden unterschiedliche Tests anhand eines ausgewählten Testgebietes in Hannover durchgeführt, das in Kapitel 4.1 vorgestellt wird. Um die Ergebnisse bewerten zu können, werden in Kapitel 4.2 die verwendeten Qualitätsmaße erläutert. In Kapitel 4.3 wird zunächst die Nachbarschaftsgröße festgelegt. Außerdem wird bewertet, welcher Ansatz zum Entwurf des Graphen, also der Ansatz kNN oder Ansatz mit der zylindrischen Umgebung, für weitere Untersuchungen nützlicher ist. Nach der Auswahl des Ansatzes wird im darauffolgenden Kapitel untersucht, welche Modelle für das paarweise Cliquespotential (MRF) und das Interaktionspotential (CRF) besser geeignet sind. Nach diesem Test folgt in Kapitel 4.5 der Vergleich zwischen den drei Verfahren SVM, MRF und CRF. Anschließend werden in dem Kapitel 4.6 einzelne Komponenten der CRF analysiert, um mögliche Verbesserungen bei der Klassifikation zu erhalten.

Die Durchführungen für die MRF und CRF werden mit der Matlab Toolbox UGM auf einem Rechner mit 3,2 GHz Intel Core i7 CPU und 24 GB RAM realisiert [Schmidt 2012]. Für die SVM wird die Implementierung LIBSVM [Chang 2012] verwendet.

### 4.1 Testgebiet

Als Testgebiet wird Hannover Nordstadt in der Umgebung  $52^{\circ} 23' 24''$  nördlich und  $9^{\circ} 43' 2''$  östlich ausgewählt und in drei Gebiete (Hannover 1-3) unterteilt (Abb. 4.1 und Abb. 4.2). Die Aufnahme wurde von der Firma Milan Geoservice mit dem Airborne Laserscanner RIEGL LMS-Q560 am 10. August 2010 durchgeführt. Im Testgebiet wurden 929.831 Punkte bei einer Gesamtfläche von ca. 10,7ha mit einer durchschnittlichen Punktdichte von 9 Punkte/m<sup>2</sup> aufgenommen. Zusätzlich muss

erwähnt werden, dass für das Testgebiet keine Echobreite zur Verfügung steht.




Abb. 4.1: Luftbilder der drei Gebiete (Hannover 1 - oben, Hannover 2 - Mitte, Hannover 3 - unten) [Google Maps]



Abb. 4.2: Referenzpunktvolke der drei Gebiete (gelb-Boden, magenta-Gebäude, blau-Gebüsch, grün-Bäume)

Die dazugehörigen Referenzdaten für das Training wurden manuell erzeugt. Als Referenzklassen werden Boden (Klasse *Boden* in gelb), Gebäude mit Garagen (Klasse *Gebäude* in magenta), niedrige Vegetation mit Fahrzeugen und Zäunen (Klasse *Gebüsch* in blau) sowie Bäume (Klasse *Bäume* in grün) verwendet. Im folgenden werden für alle Darstellungen diese Farben verwendet. Die Verteilung der Punktzahl der unterschiedlichen Objektklassen in den Gebieten ist der Tabelle 1 zu entnehmen.

Referenzklassen	Hannover 1		Hannover 2		Hannover 3	
	Punktzahl	Prozent	Punktzahl	Prozent	Punktzahl	Prozent
<i>Boden</i>	180.845	48,4	153.477	53,2	115.413	43,1
<i>Gebäude</i>	73.378	19,6	40.999	14,2	93.337	34,9
<i>Gebüsch</i>	20.376	5,5	15.207	5,3	10.117	3,8
<i>Bäume</i>	99.112	26,5	78.898	27,3	48.672	18,2

Tabelle 1: Verteilung der Objektklassen in den Testgebieten

## 4.2 Bewertung anhand von Qualitätsmaßen

Bei der Bewertung soll die Qualität der Ergebnisse der verwendeten Algorithmen SVM, MRF und CRF mit Hilfe von Referenzdaten kontrolliert werden. Dabei lassen sich die Punkte durch Vergleich der Ergebnisse nach der Klassifikation mit den Referenzdaten in die Kategorien True Positive (TP), False Negative (FN), True Negative (TN) und False Positive (FP) einteilen. Wenn die Klasse (*Boden*, *Gebäude*,

## 4.2 Bewertung anhand von Qualitätsmaßen

---

*Gebüsch* und *Bäume*) nach der Klassifikation dieselbe ist wie in der Referenz, so wird der Punkt der Kategorie TP zugeordnet. Ein FN entsteht dann, wenn ein Punkt z.B. in der Referenz zur Klasse *Boden* gehört, aber bei der Klassifikation der Klasse *Nicht-Boden* zugeordnet wird. Punkte, die als *Boden* klassifiziert werden, aber in der Referenz als *Nicht-Boden* bezeichnet werden, sind FP. Die Kategorie TN entsteht dann, wenn ein Punkt bei der Klassifikation als *Nicht-Boden* eingeteilt wird und bei der Referenz ebenfalls zu der Klasse *Nicht-Boden* gehört.

Aus diesen Kategorien können dann die Qualitätsmaße Vollständigkeit, Korrektheit und Qualität nach [Heipke 1997] ermittelt werden. Zusätzlich kann noch eine Konfusionsmatrix aufgestellt werden, die die Anzahl von TP, FN, TN, FP enthält.

### Vollständigkeit

Die Vollständigkeit beschreibt, wie viele Punkte detektiert werden konnten. Diese lässt sich wie folgt bestimmen, wobei die Anzahl mit # gekennzeichnet wird:

$$\text{Vollständigkeit} [\%] = 100 \cdot \frac{\#TP}{\#TP + \#FN} \quad (4.1)$$

### Korrektheit

Mit dem Qualitätsmaß Korrektheit (Formel (4.2)) wird der Anteil der Punkte angegeben, der auch der Referenz entspricht. Für eine gute Klassifikation müssen Korrektheit und Vollständigkeit möglichst groß sein.

$$\text{Korrektheit} [\%] = 100 \cdot \frac{\#TP}{\#TP + \#FP} \quad (4.2)$$

### Qualität

Durch die Qualität werden Vollständigkeit und Korrektheit miteinander verbunden. Dieses Maß lässt sich auf zwei Wegen bestimmen:

## 4.2 Bewertung anhand von Qualitätsmaßen

$$\text{Qualität} [\%] = 100 \cdot \frac{\#TP}{\#TP + \#FN + \#FP} \quad (4.3)$$

$$\text{Qualität} [\%] = \frac{\text{Vollst.} \cdot \text{Korr.}}{\text{Vollst.} + \text{Korr.} - \text{Vollst.} \cdot \text{Korr.}} \quad (4.4)$$

### 4.3 Bestimmung der Nachbarschaftsgröße im Graphen

In diesem Test soll herausgefunden werden, wie sich die Ergebnisse der Klassifikation verändern, wenn man beim Entwurf des Graphen entweder den Ansatz der kNN oder den Ansatz mit der zylindrischen Umgebung verwendet. Für die Tests in diesem Kapitel wurde ein größeres Testgebiet in Hannover genutzt, das in vier Teilgebiete (Han1-4) mit ca. 560.000 Punkten pro Gebiet unterteilt wurde.

Zunächst wird die optimale Anzahl an Nachbarn für den Graphen mittels CRF ermittelt. Als Trainingsgebiet wird ein kleinerer Ausschnitt von Han4 verwendet. Nun wird die Nachbaranzahl verändert und der Mittelwert aller Gesamtgenauigkeiten aus den vier Teilgebieten beobachtet. Die Ergebnisse sind in der Abb. 4.3 dargestellt. Der Mittelwert bei allen möglichen Variationen an Nachbarn liegt zwischen 92% - 93,5%, so dass der Unterschied relativ gering ist. Der beste Mittelwert der Gesamtgenauigkeiten wird mit einem Nachbarn (93,36%) erreicht, danach folgt der

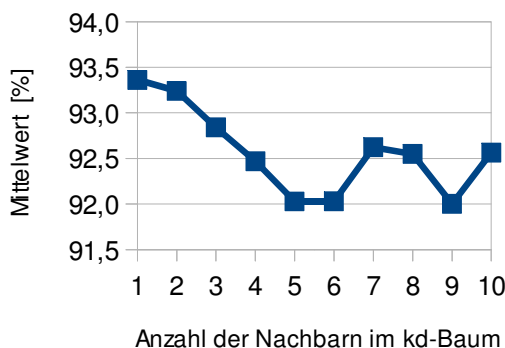


Abb. 4.3: Mittelwert der Gesamtgenauigkeiten




Abb. 4.4: Berechnungszeit für das Training

### 4.3 Bestimmung der Nachbarschaftsgröße im Graphen

Mittelwert mit zwei Nachbarn (93,24%), drei Nachbarn (92,84%) und 7 Nachbarn (92,62%). Betrachtet man die Berechnungszeit, insbesondere für das Training (Abb. 4.4), so kann man feststellen, dass diese mit einer höheren Anzahl an Nachbarn steigt. Da in dieser Masterarbeit untersucht werden soll, inwieweit sich Kontextwissen auf die Klassifikation auswirkt und die Unterschiede bei dem Mittelwert der Gesamtgenauigkeiten bei den verschiedenen Nachbarn relativ gering sind, wird die Anzahl an Nachbarn aufgrund von mehr Kontextinformation und der geringeren Berechnungszeit beim Training auf drei festgelegt.

Um nun zu testen, ob der Ansatz des kNN oder die zylindrische Umgebung geeigneter ist, wird mit Hilfe der Formel (4.5) ein vergleichbarer Zylinderradius mit  $r=0,33m$  [Niemeyer 2011] berechnet. Dabei werden mit dem Ansatz kNN genau drei Nachbarn pro Punkt und bei dem Ansatz mit der zylindrischen Umgebung ungefähr drei Nachbarn pro Punkt bestimmt.

$$r = \sqrt{\frac{\text{Anzahl der Nachbarn}}{\text{Punktdichte} \cdot \pi}} \quad (4.5)$$

		kNN	Zylinder	Differenz: kNN-Zylinder
Boden	Korrektheit	95,71	96,34	-0,63
	Vollständigkeit	96,60	96,05	0,55
	Qualität	92,59	92,67	-0,08
Gebäude	Korrektheit	95,38	95,06	0,32
	Vollständigkeit	95,59	95,43	0,17
	Qualität	91,36	90,92	0,44
Gebüsch	Korrektheit	57,31	56,49	0,82
	Vollständigkeit	55,53	57,05	-1,52
	Qualität	39,28	39,64	-0,35
Bäume	Korrektheit	94,87	93,87	1,00
	Vollständigkeit	93,31	93,79	-0,48
	Qualität	88,83	88,38	0,45
<b>Gesamtgenauigkeit</b>		93,71	93,66	0,05

Tabelle 2: Qualitätsmaße und Gesamtgenauigkeit in Prozent für Ansatz kNN und Ansatz zylindrische Umgebung (Zylinder) sowie deren Differenz

### 4.3 Bestimmung der Nachbarschaftsgröße im Graphen

Für die beiden Ansätze wurde die sogenannte Cross Validation angewendet. Hierbei werden die Parameter jeweils mit drei Gebieten trainiert und bei der Klassifikation das verbleibende Gebiet angewendet (vgl. Tabelle 3). Somit ist beispielsweise die Berechnungszeit für das Training in Han4 aufgrund der größeren Anzahl an verwendeten Punkten für das Training (1,8 Mio. Punkte) länger als für Han1 (1,5 Mio. Punkte).

Die Ergebnisse der beiden Ansätze sind in der Tabelle 2 dargestellt. Wird das Maß Qualität, das sich aus der Vollständigkeit und Korrektheit berechnen lässt (vgl. Kapitel 4.2), in allen vier Klassen betrachtet, so kann man nur geringe Unterschiede in den beiden Ansätzen beobachten. In den Klassen *Boden* und *Gebüsch* werden mit dem Ansatz zylindrische Umgebung bessere Werte ( $-\Delta 0,1\%$  und  $-\Delta 0,4\%$ ) erreicht. Für die Klasse *Gebüsch* werden für die Korrektheit, Vollständigkeit und somit Qualität nur deshalb so geringe Werte mit beiden Ansätzen erreicht, weil diese Klasse eine geringe Anzahl an Punkten in den Referenzdaten enthält (vgl. Tabelle 1). Außerdem sind sehr unterschiedliche Objekte in dieser Referenzklasse wie niedrige Vegetation, Fahrzeuge und Zäune enthalten. Für die Klassen *Gebäude* und *Bäume* werden mit dem Ansatz kNN bessere Werte ( $\Delta 0,4\%$  und  $\Delta 0,5\%$ ) erreicht. Bei der Gesamtgenauigkeit sind ebenfalls kaum Unterschiede zwischen den beiden Ansätzen zu erkennen. Betrachtet man jedoch die Berechnungszeit (Tabelle 3), so wird deutlich, dass der Ansatz mit der zylindrischen Umgebung beim Training und Testen fast drei mal so viel Zeit benötigt wie der Ansatz kNN.

Gebiet	Han1		Han2		Han3		Han4	
Punkte pro Gebiet	750.440		517.969		561.558		411.144	
Punkte für Training	1.490.671		1.723.142		1.679.553		1.829.967	
Ansatz	kNN	Zylinder	kNN	Zylinder	kNN	Zylinder	kNN	Zylinder
Training [h]	43	93	58	53	45	140	66	282
Testen [min]	6	46	6	29	9	8	7	5

Tabelle 3: Berechnungszeit Ansatz kNN und Ansatz Zylinder

Aufgrund der geringfügigen Unterschiede in der Gesamtgenauigkeit und der zu langen Berechnungszeit beim Ansatz zylindrische Umgebung, wird künftig für alle weiteren Tests der Ansatz kNN gewählt.

#### 4.4 Test zu den Modellen des Cliquen- bzw. Interaktionspotentials

In diesem Experiment sollen in den MRF und CRF jeweils unterschiedliche Modelle wie das Potts-Modell, das erweiterte Potts-Modell und das Modell des vollen Potentials für das Cliquen- bzw. das Interaktionspotential untersucht werden. Für beide Verfahren wird ebenfalls die Cross Validation angewendet.

Wie erwartet kann man feststellen, dass für das paarweise Cliquenpotential in den MRF mit dem Modell des vollen Potentials der bessere Wert (93,6%) für die Gesamtgenauigkeit der Klassifikation erreicht wird (siehe Tabelle 4). Auch bei dem Maß Qualität für alle vier Klassen wird bestätigt, dass das Modell des vollen Potentials die besseren Ergebnisse erzielt. Die schlechteste Gesamtgenauigkeit wird mit dem Potts-Modell mit 92,5% erreicht. Das liegt daran, dass mit diesem Modell nur für den Fall identischer Klassen dasselbe Gewicht für jedes Merkmal trainiert wird. Auch bei dem Maß Qualität werden die schlechteren Ergebnisse ebenfalls widerspiegelt. Lediglich in der Klasse *Gebäude* ist die Qualität um 0,3% besser als mit dem erweiterten Potts-Modell. Die Klasse *Bäume* erzielt die gleichen Werte (89,3%) im Potts-Modell und im erweiterten Potts-Modell.

		Potts-Modell	Erweitertes Potts-Modell	Modell des vollen Potentials
<i>Boden</i>	Korrektheit	94,0	95,2	96,1
	Vollständigkeit	96,9	97,3	97,3
	Qualität	91,3	92,7	93,5
<i>Gebäude</i>	Korrektheit	93,0	93,1	92,8
	Vollständigkeit	92,1	91,6	92,8
	Qualität	86,1	85,8	86,6
<i>Gebüsch</i>	Korrektheit	63,3	64,6	65,6
	Vollständigkeit	53,9	59,8	62,3
	Qualität	41,1	45,1	46,9
<i>Bäume</i>	Korrektheit	95,1	94,9	95,2
	Vollständigkeit	93,6	93,8	93,9
	Qualität	89,3	89,3	89,7
<b>Gesamtgenauigkeit</b>		92,5	93,2	93,6

Tabelle 4: Qualitätsmaße und Gesamtgenauigkeit in Prozent für die unterschiedlichen Modelle des Cliquenpotentials (MRF)



#### 4.4 Test zu den Modellen des Cliquen- bzw. Interaktionspotentials

Die Abbildungen 4.5-4.8 zeigen ein Beispiel, wie die Punktwolke mit den unterschiedlichen Modellen für das Cliquenpotential aussieht. Die in den Referenzdaten als blau gekennzeichneten Punkte sind teilweise Gebüsch und Grabsteine, die sich auf einem Friedhof befinden. Besonders mit dem Potts-Modell werden viele Punkte, die sich auf dem Boden befinden, fälschlicherweise der Klasse *Gebüsch* und *Gebäude* zugeordnet. Im Vergleich dazu werden mit dem Modell des vollen Potentials deutlich weniger dieser Punkte falsch klassifiziert. Der Grund für die falsch klassifizierten Punkte insbesondere beim Potts-Modell und teilweise auch beim erweiterten Potts-Modell ist der Effekt der geglätteten Klassifikation. In diesen wird modelliert, dass die Wahrscheinlichkeit geringer ist, dass sich Klassen benachbarter Punkte unterscheiden. Dafür werden beim Modell des vollen Potentials kleinere Details, die in der Klasse *Gebüsch* enthalten sind, besser erhalten.




Abb. 4.5: Referenzdaten (MRF)




Abb. 4.6: Klassifikation mit Potts-Modell (MRF)




Abb. 4.7: Klassifikation mit Modell des vollen Potentials (MRF)




Abb. 4.8: Klassifikation mit erweitertem Potts-Modell (MRF)

#### 4.4 Test zu den Modellen des Cliquen- bzw. Interaktionspotentials

Auch für das Interaktionspotential bei den CRF (Tabelle 5) ist ein besserer Wert für die Gesamtgenauigkeit mit dem Modell des vollen Potentials (93,7%) im Vergleich zum Potts-Modell (93,1%) und dem erweiterten Potts-Modell (93,3%) zu beobachten. Unterscheidet man zwischen der Qualität in den jeweiligen Klassen, so lässt sich feststellen, dass für die Klassen *Boden* und *Gebüsch* die Qualität beim Modell des vollen Potentials die besten Werte (93,9% und 46,2%) und beim Potts-Modell die schlechtesten Werte (92,4% und 43,1%) erreicht. Für die Klasse *Gebäude* wird für die Qualität mit dem Potts-Modell der beste Wert (86,8%) erreicht, mit 0,2% weniger folgt das Modell des vollen Potentials. Das erweiterte Potts-Modell liefert den schlechtesten Wert (85,6%) für diese Klasse. Für die Klasse *Bäume* wird entsprechend mit dem Potts-Modell der beste Wert (89,7%), ein geringfügig schlechterer Wert mit dem Modell des vollen Potentials (89,5%) und der schlechteste mit dem erweiterten Potts-Modell (88,9%) für die Qualität erzielt. Auch hier fällt auf, dass mit dem Modell des vollen Potentials kleinere Details besser erhalten werden können.

		Potts-Modell	Erweitertes Potts-Modell	Modell des vollen Potentials
<i>Boden</i>	Korrektheit	95,0	96,2	96,6
	Vollständigkeit	97,0	97,0	97,1
	Qualität	92,4	93,4	93,9
<i>Gebäude</i>	Korrektheit	92,7	92,0	92,4
	Vollständigkeit	93,1	92,5	93,3
	Qualität	86,8	85,6	86,6
<i>Gebüsch</i>	Korrektheit	64,0	61,5	62,7
	Vollständigkeit	56,9	62,3	63,7
	Qualität	43,1	44,8	46,2
<i>Bäume</i>	Korrektheit	95,5	95,3	95,6
	Vollständigkeit	93,7	93,0	93,4
	Qualität	89,7	88,9	89,5
<b>Gesamtgenauigkeit</b>		93,1	93,3	93,7

Tabelle 5: Qualitätsmaße und Gesamtgenauigkeit in Prozent für die unterschiedlichen Modelle des Interaktionspotentials (CRF)

Vergleicht man die Berechnungszeit der verschiedenen Modelle für die MRF (Tabelle 6) und CRF (Tabelle 7), so wird deutlich, dass für das Training Stunden und für das Testen weniger als eine Minute benötigt werden. Da für das Modell des

#### 4.4 Test zu den Modellen des Cliquen- bzw. Interaktionspotentials

vollen Potentials je ein Gewicht für jede Klassenkombination, für das erweiterte Potts-Modell ein Gewichtsvektor für gleiche Klassenkombinationen und für das Potts-Modell ein konstantes Gewicht trainiert werden muss, wird vermutet, dass dementsprechend das Modell des vollen Potentials die meiste Zeit beim Training benötigt und das Potts-Modell die geringste. Unerwarteterweise wird für die MRF beim erweiterten Potts-Modell die meiste Zeit mit insgesamt 22 Stunden benötigt. Beim Modell des vollen Potentials werden 17 Stunden und beim Potts-Modell 16 Stunden benötigt. Bei den CRF braucht nun das Modell des vollen Potentials 40 Stunden, das Potts-Modell 27 Stunden und das erweiterte Potts-Modell 14 Stunden für das Training.

		Hannover 1	Hannover 2	Hannover 3
<b>Punkte pro Gebiet</b>		373.711	288.581	267.539
<b>Punkte für Training</b>		556.120	641.250	662.292
<b>Potts-Modell</b>	<b>Training [h]</b>	6,0	4,3	5,4
	<b>Testen [s]</b>	16	19	12
<b>erweitertes Potts-Modell</b>	<b>Training [h]</b>	5,3	10,6	6,4
	<b>Testen [s]</b>	50	19	17
<b>Modell des vollen Potentials</b>	<b>Training [h]</b>	2,8	6,3	7,9
	<b>Testen [s]</b>	45	14	22

*Tabelle 6: Berechnungszeit der verschiedenen Modelle für die MRF*

		Hannover 1	Hannover 2	Hannover 3
<b>Punkte pro Gebiet</b>		373.711	288.581	267.539
<b>Punkte für Training</b>		556.120	641.250	662.292
<b>Potts-Modell</b>	<b>Training [h]</b>	6,3	9,0	11,7
	<b>Testen [s]</b>	49	17	16
<b>erweitertes Potts-Modell</b>	<b>Training [h]</b>	3,5	4,5	5,8
	<b>Testen [s]</b>	37	17	25
<b>Modelle des vollen Potentials</b>	<b>Training [h]</b>	8,1	15,3	17,0
	<b>Testen [s]</b>	31	29	29

*Tabelle 7: Berechnungszeit der verschiedenen Modelle für die CRF*

Für das Cliquenpotential und das Interaktionspotential werden mit dem Modell des vollen Potentials die besseren Ergebnisse bei der Klassifikation erreicht. Das liegt daran, dass für alle möglichen Klassenkombinationen unterschiedliche Gewichte angelernt werden und das Gebiet somit besser beschrieben werden kann. Zudem können kleinere Details wie in der Klasse *Gebüsch* besser erhalten werden. Als

## 4.4 Test zu den Modellen des Cliques- bzw. Interaktionspotentials

Nachteil kann angesehen werden, dass nur im Fall der CRF eine deutlich größere Berechnungszeit für das Modell des vollen Potentials benötigt wird. Bei den MRF liegt die Berechnungszeit knapp über der des Potts-Modells. Aufgrund der positiven Eigenschaften des Modells des vollen Potentials werden alle folgenden Berechnungen mit diesem Modell durchgeführt.

## 4.5 Vergleich zwischen SVM, MRF und CRF

Hauptziel dieser Masterarbeit ist es zu untersuchen, ob eine Verbesserung erreicht werden kann, wenn Kontextinformationen in der Klassifikation berücksichtigt werden. Dazu werden die kontextbasierten Verfahren MRF und CRF mit den SVM, die keine Kontextinformationen beinhalten, verglichen. Bei jedem der drei Verfahren wurde die Cross Validation angewendet. Hierbei werden die Parameter jeweils mit zwei Gebieten trainiert und bei der Klassifikation das verbleibende Gebiet angewendet (vgl. Tabelle 9).

Hannover		SVM	MRF	CRF
Boden	Korrektheit	96,1	96,1	96,6
	Vollständigkeit	97,7	97,3	97,1
	Qualität	94,0	93,5	93,9
Gebäude	Korrektheit	91,2	92,8	92,4
	Vollständigkeit	93,5	92,8	93,3
	Qualität	85,8	86,6	86,6
Gebüsch	Korrektheit	71,7	65,6	62,7
	Vollständigkeit	59,2	62,3	63,7
	Qualität	48,0	46,9	46,2
Bäume	Korrektheit	94,1	95,2	95,6
	Vollständigkeit	93,0	93,9	93,4
	Qualität	87,8	89,7	89,5
<b>Gesamtgenauigkeit</b>		93,3	93,6	93,7

Tabelle 8: Qualitätsmaße und Gesamtgenauigkeit in Prozent für die Ergebnisse von SVM, MRF, CRF

Die Ergebnisse der Klassifikation mit den drei unterschiedlichen Verfahren SVM, MRF und CRF mit ihren Qualitätsmaßen und der Gesamtgenauigkeit sind in Tabelle

## 4.5 Vergleich zwischen SVM, MRF und CRF

8 enthalten. Wie erwartet, wird die beste Gesamtgenauigkeit mit den CRF (93,7%) erreicht. Mit einem geringfügig schlechteren Wert folgen die MRF (93,6%) und die SVM sind um 0,4% in der Gesamtgenauigkeit schlechter als die CRF. Betrachtet man die Qualität, so wird für die Klasse *Boden* der bessere Wert mit den SVM (94,0%) erreicht, mit nur 0,1% weniger folgen die CRF und mit 0,5% die MRF. Für die Klasse *Gebäude* erreicht die Qualität mit dem Verfahren CRF und MRF den gleichen Wert mit 86,8%. Die SVM sind um 0,8% schlechter als die CRF und MRF. Für *Gebüsch* hingegen ergibt sich eine Qualität mit den SVM von 48,0%, mit 1,1% weniger folgen die MRF, mit 1,8% die CRF. Im Gegensatz dazu wird wiederum für die Klasse *Bäume* mit den SVM das schlechteste Ergebnis für die Qualität mit 87,8% erzielt. Die CRF haben einen um 1,7% und die MRF einen um 1,9% besseren Wert.




Abb. 4.9: Referenzdaten




Abb. 4.10: Klassifikation SVM




Abb. 4.11: Klassifikation MRF




Abb. 4.12: Klassifikation CRF

Diese Ergebnisse der Qualität in den einzelnen Klassen lassen sich auch in den

## 4.5 Vergleich zwischen SVM, MRF und CRF

---

klassifizierten Punktwolken in einem kleinen Ausschnitt widerspiegeln (siehe Abb. 4.9-Abb. 4.12). Für die Klasse *Gebäude* werden mit den SVM besonders auf den Häuserfassaden (siehe roter Pfeil) viele Punkte falsch klassifiziert. Durch den Kontext in den MRF und CRF können an dieser Stelle Häuserfassaden etwas besser klassifiziert werden. Auch in der Klasse *Bäume* (siehe weißer Pfeil) können unter Einbeziehung von Kontext Punkte mit den MRF und CRF richtig zugeordnet werden, mit den SVM werden hier deutlich mehr Punkte falsch klassifiziert.

Auch in den Abbildungen 4.13-4.16 lassen sich die Unterschiede nochmals exemplarisch in den Punktwolken eines Ausschnitts bestätigen. Die Abb. 4.17 verdeutlicht durch ein Luftbild den untersuchten Ausschnitt, der allerdings nicht zum selben Zeitpunkt wie die Laserpunktwolke aufgenommen wurde. In diesem Abschnitt sieht man im Westen ein Gewächshaus, das ein Glasdach hat und mehrere Erdhügel in der Nähe. Festzustellen ist, dass bei allen drei Verfahren das Gewächshaus nicht richtig klassifiziert werden konnte. Der Grund dafür ist, dass der Laserpuls Glas durchdringen kann, somit Laserpunkte auf dem Boden gemessen werden können und dadurch die Intensität eine andere ist, als bei den restlichen Gebäuden. Insbesondere für die kontextbasierten Verfahren werden in der volumetrischen Umgebung bei Berechnung der Merkmale die Punkte auf dem Boden hinzugezogen. Durch diese Verteilung werden dann Punkte, die eigentlich zur Klasse *Gebäude* gehören, wahrscheinlicher der Klasse *Bäume* oder *Gebüsch* zugeordnet. Bei den Erdhügeln ist festzustellen, dass bei den SVM im Vergleich zu den kontextbasierten Verfahren deutlich mehr Punkte der richtigen Klasse *Boden* zugeordnet werden. Nur einige dieser Punkte werden jedoch der Klasse *Gebäude* zugeordnet. Das liegt vermutlich an der Neigung der Erdhügel, die einer Dachneigung ähnelt. Somit sprechen die Merkmale Neigungswinkel und Höhe eher für *Gebäude* als für *Boden*. Bei den MRF werden mehr Punkte fälschlicherweise der Klasse *Gebäude* aufgrund des Kontextes zugeordnet. Und bei den CRF werden aufgrund der Interaktionsmerkmale noch weitere Punkte der Klasse *Gebüsch* zugeordnet. Durch die Interaktionsmerkmale wird modelliert, dass es wahrscheinlicher ist, dass sich neben der Klasse *Gebäude* die Klasse *Gebüsch* befindet und nicht die Klasse *Boden*. Punkte, die somit einen größeren Wert für die



## 4.5 Vergleich zwischen SVM, MRF und CRF

Höhe aufweisen, werden eher als *Gebäude* klassifiziert. Punkte, die einen geringeren Wert für die Höhe aufweisen, aber trotzdem über dem Boden liegen, werden als *Gebüsch* klassifiziert.




Abb. 4.13: Referenzdaten




Abb. 4.14: Klassifikation SVM




Abb. 4.15: Klassifikation MRF




Abb. 4.16: Klassifikation CRF



Abb. 4.17: Luftbild des gezeigten Gebietes [Bing Maps]

## 4.5 Vergleich zwischen SVM, MRF und CRF

Betrachtet man die Berechnungszeit (Tabelle 9) so wird deutlich, dass das Training bei allen drei Verfahren mehr Zeit benötigt und das Testen im Gegensatz dazu schneller durchgeführt wird. Im Vergleich der Berechnungszeit zwischen den unterschiedlichen Verfahren zeigt sich, dass die SVM die längste Zeit beim Training und Testen benötigen. Während für das Training insgesamt für alle Gebiete fast vier Tage benötigt werden, dauert das Testen pro Gebiet ungefähr eine Stunde. Allerdings wird vermutet, dass die Berechnungszeit für die SVM deshalb so lange dauert, weil intern eine weitere Cross Validation durchgeführt wird. Hinweise darauf konnten jedoch nicht gefunden werden. Auch ein Unterschied zwischen den MRF und CRF ist festzustellen. Beim Training benötigen die MRF insgesamt 17 Stunden, die CRF hingegen 40 Stunden. Die größere Berechnungszeit in den CRF ist damit zu erklären, dass bei den CRF zusätzlich noch Interaktionsmerkmale enthalten sind, die trainiert werden müssen. Beim Testen fallen zwischen den MRF und CRF kaum Unterschiede auf. Nur im Vergleich zu den SVM wird hier das Testen unter einer Minute durchgeführt.

Gebiet		Hannover 1	Hannover 2	Hannover 3
Punkte pro Gebiet		373.711	288.581	267.539
Punkte für Training		556.120	641.250	662.292
SVM	Training [h]	26,5	34,0	30,7
	Testen [min]	68	69	61
MRF	Training [h]	2,8	6,3	7,9
	Testen [s]	45	14	22
CRF	Training [h]	8,1	15,3	17,0
	Testen [s]	31	29	29

*Tabelle 9: Anzahl der Punkte pro Gebiet und für das Training sowie Berechnungszeit für das Training und Testen für die jeweiligen Gebiete*

Zusammenfassend lässt sich wie erwartet sagen, dass die beste Gesamtgenauigkeit mit den CRF erreicht werden kann. Das liegt daran, dass bei den CRF nicht nur die Daten im jeweiligen Knoten berücksichtigt werden, wie das der Fall bei den MRF ist, sondern potentiell von allen Daten abhängig sind. Die Gesamtgenauigkeit bei den MRF ist nur geringfügig schlechter. Der Grund für den geringfügigen Unterschied ist, dass in den CRF wie in den MRF nur die lokale Nachbarschaft und nicht wie



vorgesehen der globale Kontext von Klassen und Daten genutzt wird. Die SVM liefern - wie erwartet - die schlechtesten Ergebnisse in der Gesamtgenauigkeit aufgrund fehlenden Kontextwissens. Das bedeutet, dass Kontextinformation mit Hilfe der MRF und CRF eine Verbesserung bei den Klassifikationsergebnissen liefern kann.

### **4.6 Analyse einzelner CRF-Komponenten**

In diesem Abschnitt sollen einzelne Komponenten der CRF analysiert werden. Es soll festgestellt werden, ob sich durch Veränderungen dieser Komponenten die Ergebnisse der Klassifikation verändern. In Kapitel 4.6.1 wird zunächst untersucht, ob sich durch die Auswahl bestimmter Interaktionsmerkmale die Ergebnisse beeinflussen lassen. Im nachfolgenden Kapitel 4.6.2 wird die Anzahl der Nachbarn im Graphen erhöht und die Ergebnisse bewertet. Im weiteren Kapitel 4.6.3 soll untersucht werden, ob es einen Einfluss geben kann, wenn anstatt direkter Nachbarn für den Graphen zufällige Nachbarn ausgewählt werden. Und im letzten Kapitel 4.6.4 werden dann die zwei besten der oben genannten Konfigurationen kombiniert.

#### **4.6.1 Verwendung ausgewählter Interaktionsmerkmale**

In diesen Experimenten soll untersucht werden, ob sich die Ergebnisse der CRF aus Kapitel 4.5 optimieren lassen. Das soll geschehen, indem nur ausgewählte Interaktionsmerkmale aufgestellt und nicht alle Merkmale verwendet werden. Wie schon beschrieben, werden die Interaktionsmerkmale aus der Differenz zweier benachbarter Merkmalsvektoren berechnet. Das bedeutet, dass die Interaktionsmerkmalsvektoren  $\mu_{ij}(x)$  in diesen Experimenten aus weniger Komponenten bestehen. In dem ersten Experiment wird getestet, inwieweit sich die Ergebnisse ändern, wenn ausschließlich die Differenz der Höhen als

## 4.6 Analyse einzelner CRF-Komponenten

Interaktionsmerkmal genutzt wird. In einem weiteren Experiment wird untersucht, wie sich die Ergebnisse ändern, wenn die Differenz der Höhen und der Amplituden in den Interaktionsmerkmalsvektoren enthalten ist. Die Ergebnisse der Experimente im Vergleich zu den CRF mit allen Interaktionsmerkmalen sind der Tabelle 10 zu entnehmen.

Interaktionsmerkmale		Alle	Höhen- unterschiede	Höhen- und Amplituden- unterschiede
<i>Boden</i>	Korrektheit	96,6	96,3	96,3
	Vollständigkeit	97,1	97,2	97,2
	Qualität	93,9	93,7	93,7
<i>Gebäude</i>	Korrektheit	92,4	92,8	92,7
	Vollständigkeit	93,3	94,1	93,7
	Qualität	86,6	87,7	87,3
<i>Gebüsch</i>	Korrektheit	62,7	65,8	65,4
	Vollständigkeit	63,7	62,0	62,4
	Qualität	46,2	46,9	46,9
<i>Bäume</i>	Korrektheit	95,6	95,7	95,6
	Vollständigkeit	93,4	93,9	93,8
	Qualität	89,5	90,0	89,9
<b>Mittelwert der Qualität</b>		79,0	79,6	79,5
<b>Gesamtgenauigkeit</b>		93,7	93,9	93,8

*Tabelle 10: Qualitätsmaße und Gesamtgenauigkeit in Prozent für CRF mit allen Interaktionsmerkmalen, mit Höhenunterschieden oder mit Höhen- und Amplitudenunterschieden*

Tatsächlich bringt nur die Nutzung der Höhenunterschiede als Interaktionsmerkmal eine Verbesserung gegenüber der Nutzung aller Merkmale in der Gesamtgenauigkeit um 0,2%. Nutzt man die Höhen- und Amplitudenunterschiede, so wird eine Verbesserung in der Gesamtgenauigkeit um 0,1% erreicht.

Vergleicht man die Qualität in der Klasse *Boden*, so wird deutlich, dass die beste Qualität mit allen Interaktionsmerkmalen (93,9%) erreicht werden kann, die beiden anderen Ansätze liefern einen um 0,2% schlechteren Wert. Für die Klasse *Gebäude* kann der Wert für die Qualität um 1,1% verbessert werden, wenn anstatt aller Interaktionsmerkmale nur die Höhenunterschiede verwendet werden. Dasselbe ist auch für die Klasse *Gebüsch* zu sehen. Hier wird der Wert um 0,7% verbessert. Und auch der Wert für die Klasse *Bäume* wird durch die Nutzung der Höhenunterschiede

## 4.6 Analyse einzelner CRF-Komponenten

um 0,5% im Gegensatz zur Nutzung aller Interaktionsmerkmale verbessert. Mittelt man die Qualität über allen Klassen, so wird die Verbesserung bei Nutzung der Höhenunterschiede als Interaktionsmerkmale (79,6%) gegenüber Nutzung aller Merkmale (79,0%) auch hier deutlich.




Abb. 4.18: Referenzdaten




Abb. 4.19: Klassifikation mit allen Interaktionsmerkmalen




Abb. 4.20: Klassifikation mit Höhen- und Amplitudenunterschieden




Abb. 4.21: Klassifikation mit Höhenunterschieden

In den Abbildungen 4.18-4.21 werden die Unterschiede an einem kleinen Ausschnitt verdeutlicht. Besonders Punkte auf dem Giebeldach werden dann am besten klassifiziert, wenn man als Interaktionsmerkmal nur die Höhenunterschiede verwendet. Am schlechtesten werden hier Punkte bei allen Interaktionsmerkmalen klassifiziert. Werden als Interaktionsmerkmale die Höhen- und Amplitudenunterschiede benutzt, so ist das Klassifikationsergebnis etwas besser als mit allen Interaktionsmerkmalen. Das liegt daran, dass durch alle Interaktionsmerkmale zu viele Informationen zur Verfügung stehen und diese das

## 4.6 Analyse einzelner CRF-Komponenten

---

Ergebnis negativ beeinflussen. Verwendet man nur die Informationen, die ausschlaggebend sind, so verbessert sich das Klassifikationsergebnis.

Zusammenfassend betrachtet bringt die Festlegung der Interaktionsmerkmale auf die Höhenunterschiede eine Verbesserung in der Gesamtgenauigkeit um 0,2% gegenüber der Nutzung aller Merkmale mit sich. Und auch bei der Qualität ist für die Objektklassen *Gebäude*, *Gebüsch* und *Bäume* eine Verbesserung zu sehen. Durch Weglassen bestimmter Interaktionsmerkmale erhält das übrig gebliebene Merkmal einen höheren Einfluss auf die Klassifikation. Die größte Steigerung der Qualität um 1,1% wird in der Klasse *Gebäude* erreicht. Die Klasse *Gebüsch* erreicht eine Verbesserung um 0,7% und die Klasse *Gebäude* um 0,5%. Lediglich in der Klasse *Boden* erreicht man mit allen Interaktionsmerkmalen einen etwas besseren Wert für die Qualität. Es zeigt sich, dass es nicht immer von Vorteil ist, alle möglichen Informationen für die Interaktionsmerkmale zu nutzen. Es kann besser sein, nur ausgewählte Interaktionsmerkmale zu benutzen. Interessant wäre es, insbesondere bei den Laserscannerdaten, nochmals den Einfluss der Echobreite zu untersuchen. Da diese aber in dem Testgebiet nicht zur Verfügung steht, war dies nicht möglich.

### 4.6.2 Erhöhung der Nachbarschaft im Graphen

In diesem Experiment soll untersucht werden, ob sich eine Erhöhung der Nachbarschaft im Graphen, insbesondere auf Bäume und Gebäude, positiv auf die Klassifikation auswirkt. Dabei sollen auf Bäumen falsch klassifizierte Gebäudepunkte und auf Gebäuden falsch klassifizierte Baumpunkte nach Möglichkeit korrigiert werden.

Bei allen Tests wird das Verfahren Cross Validation aufgrund der längeren Berechnungszeit nicht angewendet. Hierbei wird als Trainingsgebiet das kleinste Gebiet, also Hannover 3, verwendet. Wegen Speicherproblemen bei einer sehr hohen

## 4.6 Analyse einzelner CRF-Komponenten

Anzahl an Nachbarn, wurde das Feature Space Mapping bei den verallgemeinerten linearen Modellen nicht durchgeführt.

Die Anzahl an Nachbarn wird auf drei, sieben, zehn, 15, 20 und 40 festgelegt. Dabei wird zum einen die Gesamtgenauigkeit in den einzelnen Gebieten (Hannover 1-3), sowie deren Mittelwert angezeigt (siehe Tabelle 11). Zum anderen wird der Mittelwert der Qualität in den Klassen, der sich aus den einzelnen Gebieten für die jeweilige Klasse ergibt, bestimmt (siehe Abb. 4.22).

Anzahl an Nachbarn		3	7	10	15	20	40
Gesamtgenauigkeit	Hannover 1	91,3	91,7	86,4	67,7	68,9	50,2
	Hannover 2	94,1	92,8	88,1	69,4	69,1	54,0
	Hannover 3	94,6	93,2	87,8	58,3	62,1	44,0
	Mittelwert	93,3	92,6	87,5	65,1	66,7	49,4

Tabelle 11: Gesamtgenauigkeit und Mittelwert der Qualität der unterschiedlichen Anzahl an Nachbarn in Prozent

Betrachtet man den Mittelwert der Gesamtgenauigkeit aller Gebiete so fällt auf, dass dieser mit ansteigender Anzahl an Nachbarn tendenziell kleiner wird. Während für drei und sieben Nachbarn der Mittelwert der Gesamtgenauigkeit noch bei über 92% liegt und der bessere Wert mit drei Nachbarn erreicht werden kann, sinkt der Wert für zehn Nachbarn auf 87,5%. Vergleicht man den Mittelwert zwischen 15 und 20 Nachbarn so fällt auf, dass dieser bei 15 Nachbarn nur bei 65,1% liegt und bei 20 Nachbarn leicht auf 66,7% steigt. Für 40 Nachbarn liegt der Wert nur noch bei 49,4%.




Abb. 4.22: Mittelwert der Qualität für die einzelnen Klassen in Prozent

## 4.6 Analyse einzelner CRF-Komponenten

---

Dasselbe ist auch beim Mittelwert der Qualität in den einzelnen Klassen zu sehen. Mit steigender Anzahl wird die Qualität schlechter. Der beste Mittelwert der Qualität in allen Klassen wird hierbei mit drei Nachbarn erzielt. Dennoch gibt es Unterschiede in den einzelnen Klassen. Die Klasse *Boden* weist dabei als einzige Klasse einen Mittelwert von über 91% für drei und sieben Nachbarn auf. Für zehn Nachbarn fällt der Wert auf 85,0% und bei 15 Nachbarn liegt der Wert bei 58,7%. Weiterhin fällt der Wert für 20 Nachbarn auf 55,9%, während er für 40 Nachbarn nur noch 48,3% erreicht. Auch für die Klasse *Gebäude* befindet sich der Wert für drei und sieben Nachbarn bei über 85%, für zehn Nachbarn fällt er auf 73,3%. Bei 15 Nachbarn fällt der Wert auf 27,3%, während er bei 20 Nachbarn wieder auf 40,1% steigt. Für 40 Nachbarn wird nur noch ein Wert von 10,2% erreicht. Für die Klasse *Gebüsch* werden im Vergleich zu anderen Klassen die schlechtesten Werte erzielt. Bei drei Nachbarn wird ein Mittelwert der Qualität von 42,5% erreicht, bei sieben Nachbarn fällt er um 7,1% und bei zehn Nachbarn fällt der Wert nochmals auf 12,0%. Für 15, 20 und 40 Nachbarn konnte nur noch ein Wert von 0% ermittelt werden. Zuletzt konnte für die Klasse *Bäume* ein Mittelwert der Qualität für drei und sieben Nachbarn von über 87% bestimmt werden. Für zehn Nachbarn fällt der Wert auf 80,9%. Ähnlich wie in der Klasse *Gebäude* kann hier ebenfalls ein angestiegener Wert von 15 auf 20 Nachbarn von 47,2% auf 52,1% beobachtet werden. Und für 40 Nachbarn beträgt der Wert 0%.

Zusammengefasst kann gesagt werden, dass bei Erhöhung der Anzahl an Nachbarn von drei auf sieben, auf zehn, 15, 20 oder 40 Nachbarn eine Verschlechterung der Ergebnisse beobachtet werden konnte. Für den Mittelwert der Gesamtgenauigkeit und den Mittelwert der Qualität wurden mit drei Nachbarn die besten Ergebnisse erzielt.

Besonders die Erhöhung der Nachbarn in der Klasse *Gebüsch* bringt die schlechtesten Ergebnisse; ab 15 Nachbarn konnte kein Mittelwert der Qualität mehr bestimmt werden. Interessant ist, dass für die Klassen *Gebäude* und *Bäume* der Mittelwert der Qualität von 15 auf 20 Nachbarn um 12,8% bzw. um 4,9% steigt.

### 4.6.3 Zufällige Auswahl der Nachbarpunkte

Bisher wurde der Graph aus Punkten aufgebaut, die sich in der direkten Nachbarschaft befanden. In diesem Abschnitt soll nun untersucht werden, welche Auswirkung ein Graph auf die Klassifikationsergebnisse hat, der durch eine bestimmte Anzahl an zufällig gewählten Punkten aus einem Zylinder aufgebaut wird. Dafür werden aus 2000 Punkten, die sich in einem Zylinder befinden, der ungefähr einen Radius von 26,4m besitzt (vgl. Abb. 4.23), zunächst drei zufällige Nachbarn (Ansatz B) gewählt. In einem weiteren Experiment wird unter den selben Bedingungen wie im ersten Experiment ein direkter Nachbar und zwei zufällig gewählte Nachbarn (Ansatz C) verwendet. Die beiden Experimente werden mit den CRF-Ergebnissen (Ansatz A) aus Kapitel 4.5 verglichen (siehe Tabelle 12).




Abb. 4.23: Zylinderradius von ungefähr 26,4m im Testgebiet

Wie in der Tabelle zu erkennen ist, konnte mit den Ansätzen B und C eine Verbesserung gegenüber Ansatz A in der Gesamtgenauigkeit erzielt werden. Dabei verbessert sich der Wert mit dem Ansatz B um 0,5% und mit dem Ansatz C um 0,3%.

Diese Verbesserung lässt sich ebenfalls in dem Mittelwert der Qualität wieder erkennen: Mit dem Ansatz A beträgt der Mittelwert der Qualität 79,0%. Verwendet man den Ansatz C, so steigert sich der Wert um 1,4% und mit dem Ansatz B um 1,6%. Betrachtet man die Qualität in den einzelnen Klassen, so ergibt sich nur in der

## 4.6 Analyse einzelner CRF-Komponenten

Klasse *Boden* der bessere Wert für den Ansatz A (93,9%). Mit 0,2% weniger folgt der Ansatz B und mit 0,7% weniger der Ansatz C. Für die Klasse *Gebäude* kann eine Verbesserung mit 2,5% mit dem Ansatz C und 2,2% mit den Ansatz B gegenüber dem Ansatz A erzielt werden. Die größte Veränderung der Qualität kann in der Klasse *Gebüsch* gezeigt werden. Hier wird eine Verbesserung von 3,2% mit dem Ansatz B gegenüber dem Ansatz A erreicht. Auch der Ansatz C liefert ebenfalls einen um 2,0% verbesserten Wert gegenüber dem Ansatz A. Und auch in der Klasse *Bäume* können bessere Werte für die Qualität mit dem Ansatz B (90,7%) und Ansatz C (90,9%) gegenüber dem Ansatz A (89,5%) bestimmt werden.

		<b>Ansatz A</b>	<b>Ansatz B</b>	<b>Ansatz C</b>
		3 direkte Nachbarn	3 zufällige Nachbarn	1 direkter 2 zufällige Nachbarn
<i>Boden</i>	Korrektheit	96,6	96,1	95,6
	Vollständigkeit	97,1	97,4	97,3
	Qualität	93,9	93,7	93,2
<i>Gebäude</i>	Korrektheit	92,4	93,6	93,8
	Vollständigkeit	93,3	94,5	94,6
	Qualität	86,6	88,8	89,1
<i>Gebüsch</i>	Korrektheit	62,7	69,8	69,7
	Vollständigkeit	63,7	62,9	61,0
	Qualität	46,2	49,4	48,2
<i>Bäume</i>	Korrektheit	95,6	95,7	95,9
	Vollständigkeit	93,4	94,6	94,6
	Qualität	89,5	90,7	90,9
<b>Mittelwert der Qualität</b>		79,0	80,6	80,4
<b>Gesamtgenauigkeit</b>		93,7	94,2	94,0

*Tabelle 12: Qualitätsmaße und Gesamtgenauigkeit in Prozent für Ansatz A (3 direkte Nachbarn), Ansatz B (3 zufällige Nachbarn) und Ansatz C (1 direkter und 2 zufällige Nachbarn)*

In den Abbildungen 4.24-4.27 wird die Verbesserung nochmals verdeutlicht. Bei dem Ansatz A, also mit drei direkten Nachbarn, werden viele Punkte auf den Dachgauben (siehe weißer Pfeil) aufgrund der volumetrischen Verteilung und somit der Ähnlichkeit zu Bäumen der falschen Klasse *Bäume* zugeordnet. Durch die direkten Nachbarn werden nur in der unmittelbaren Nachbarschaft Punkte als Nachbarn für den Graphen gesucht. Da sich vermutlich die Merkmale der Punkte sehr ähneln, sind auch die Werte für die Interaktionsmerkmale sehr gering, wodurch eine stärkere



## 4.6 Analyse einzelner CRF-Komponenten

Glättung auftritt und somit eine größere homogene Fläche entsteht. Durch die beiden anderen Ansätzen B und C sieht man, dass die Entstehung einer homogenen Fläche unterdrückt wird. Durch die zufällige Auswahl an Nachbarn werden auch entferntere Punkte ausgewählt, deren Merkmale sich nicht so stark ähneln. Dadurch sind die Werte der Interaktionsmerkmale größer und die Glättung reduzierter. Folglich werden deutlich mehr Punkte richtig zur Klasse *Gebäude* zugeordnet.




Abb. 4.24: Referenzdaten




Abb. 4.25: Ansatz A: 3 direkte Nachbarn




Abb. 4.26: Ansatz B: 3 zufällige Nachbarn




Abb. 4.27: Ansatz C: 1 direkter und 2 zufällige Nachbarn

Zusammengefasst lässt sich deuten, dass mit dem Ansatz der drei zufällig gewählten Nachbarn für den Graphen die besten Ergebnisse, also die bessere Gesamtgenauigkeit und der bessere Mittelwert für die Qualität erreicht werden konnte. Zu erklären ist dieses Ergebnis damit, dass hier weniger stark geglättet wird,

## 4.6 Analyse einzelner CRF-Komponenten

weil nicht nur direkte Punkte, sondern weiter entferntere Punkte als Nachbarn hinzugezogen werden. Aus diesem Grund entstehen keine homogenen Flächen, wie dass zum Beispiel bei den Dachgauben der Fall ist. Eine besonders starke Veränderung in der Qualität der einzelnen Klassen ist in der Klasse *Gebüsch* festzustellen. Hier verbessert sich der Wert um 3,2% gegenüber dem Ansatz mit den drei direkten Nachbarn (Ansatz A). Auch die Klasse *Gebäude* verbessert sich um 2,2% und ebenso die Klasse *Bäume* um 1,2%. Somit kann es sinnvoll sein, die Nachbarn im Graphen nicht aus direkten Punkten aufzubauen, sondern Punkte zufällig auszuwählen.

Weil Verbesserungen für drei zufällig gewählte Nachbarn in der Qualität für die einzelnen Klassen erreicht wurden, wird in diesem Abschnitt nochmals getestet, ob sich die Ergebnisse mit fünf zufällig gewählten Nachbarn positiv verändern. Vermutet wird auch, dass mit fünf Nachbarn die Auswirkungen noch höher sein werden als mit drei Nachbarn. Die Ergebnisse mit fünf direkten und fünf zufällig gewählten Nachbarn sind in der folgenden Tabelle 13 dargestellt:

<b>Auswahl der Nachbarn</b>		5 direkte Nachbarn	5 zufällige Nachbarn
<i>Boden</i>	Korrektheit	96,4	96,0
	Vollständigkeit	96,7	97,3
	Qualität	93,3	93,5
<i>Gebäude</i>	Korrektheit	92,7	94,0
	Vollständigkeit	93,4	95,3
	Qualität	87,0	89,8
<i>Gebüsch</i>	Korrektheit	58,0	70,6
	Vollständigkeit	62,8	62,6
	Qualität	43,2	49,6
<i>Bäume</i>	Korrektheit	95,9	96,1
	Vollständigkeit	93,4	94,8
	Qualität	89,8	91,2
<b>Mittelwert der Qualität</b>		78,3	81,0
<b>Gesamtgenauigkeit</b>		93,6	94,3

*Tabelle 13: Qualitätsmaße und Gesamtgenauigkeit in Prozent für 5 direkte und 5 zufällige Nachbarn*

## 4.6 Analyse einzelner CRF-Komponenten

---

In der Gesamtgenauigkeit wird mit fünf zufälligen Nachbarn eine Verbesserung um 0,7% im Vergleich zu fünf direkten Nachbarn erzielt. Diese Steigerung fällt im Vergleich zu drei Nachbarn etwas größer aus.

In allen vier Klassen wird mit dem Ansatz der fünf zufälligen Nachbarn die bessere Qualität erreicht. Für die Klasse *Boden* wird ein um 0,2% verbesserter Wert bestimmt. Bei der Klasse *Gebäude* ist der Wert um 2,8% besser. Die größte Steigerung wird in der Klasse *Gebüsch* erreicht, hier verbessert sich der Wert sogar um 6,4%. Und auch in der Klasse *Bäume* ist ein um 1,4% besserer Wert festzustellen. Diese Verbesserungen lassen sich ebenfalls in dem Mittelwert der Qualität widerspiegeln. Hier ist ebenfalls der Ansatz mit fünf zufälligen Nachbarn um 2,7% besser als der Ansatz mit fünf direkten Nachbarn.

Zu sehen ist, dass sich die Gesamtgenauigkeit mit drei zufälligen (94,2%) und fünf zufälligen Nachbarn (94,3%) kaum unterscheidet. Jedoch der Mittelwert mit fünf zufälligen Nachbarn um 0,4% besser ist als mit drei zufälligen Nachbarn. Interessant wäre es weiterhin zu untersuchen wie die Auswirkung ist, wenn noch mehr als fünf zufällige Nachbarn gewählt werden.

### 4.6.4 Kombination der besten Konfigurationen

Da sich in den Kapiteln 4.6.1 und 4.6.3 Verbesserungen in den Ergebnissen der Klassifikation aufzeigten, sollen in diesem Abschnitt die besten Konfigurationen kombiniert werden. Erhofft wird eine nochmalige Verbesserung der Ergebnisse. Die Ergebnisse sind in der Tabelle 14 zu sehen.

Ansatz A entspricht den besten Ergebnissen aus Kapitel 4.6.1. Hier wurden als Interaktionsmerkmale nur die Höhenunterschiede verwendet und drei direkte Nachbarn gewählt. Ansatz B beschreibt die Ergebnisse aus Kapitel 4.6.3. In diesem Kapitel wurden alle Interaktionsmerkmale verwendet, jedoch drei zufällige Nachbarn

## 4.6 Analyse einzelner CRF-Komponenten

gewählt. Der Ansatz C beschreibt nun die Kombination dieser beiden Konfigurationen.

Die besten Ergebnisse in der Gesamtgenauigkeit liefert nach wie vor der Ansatz B. Ansatz C ist um 0,1% schlechter und Ansatz A um 0,3% schlechter als Ansatz B. Bei allen vier Klassen ist mit dem Ansatz A die schlechteste Qualität zu beobachten. Die anderen beiden Ansätze liefern unterschiedliche Werte für die Qualität. Für die Klasse *Boden* und *Gebäude* ist der Ansatz C um 0,1% in der Qualität besser als Ansatz B. Im Gegensatz dazu ist in der Klasse *Gebüsch* mit dem Ansatz B ein um 0,3% besserer Wert als mit dem Ansatz C zu sehen. Und auch in der Klasse *Bäume* schneidet der Ansatz B um 0,2% besser ab als der Ansatz C. Zusammengefasst variieren die Werte für die Qualität im kleinen Wertebereich zwischen Ansatz B und Ansatz C, so dass diese auch denselben Mittelwert der Qualität (80,6%) aufweisen.

		<b>Ansatz A</b>	<b>Ansatz B</b>	<b>Ansatz C</b>
<b>Interaktionsmerkmale</b>		Höhenunterschiede	Alle	Höhenunterschiede
<b>Auswahl der Nachbarn</b>		3 direkte Nachbarn	3 zufällige Nachbarn	3 zufällige Nachbarn
<i>Boden</i>	Korrektheit	96,3	96,1	96,2
	Vollständigkeit	97,2	97,4	97,4
	Qualität	93,7	93,7	93,8
<i>Gebäude</i>	Korrektheit	92,8	93,6	93,3
	Vollständigkeit	94,1	94,5	94,9
	Qualität	87,7	88,8	88,9
<i>Gebüsch</i>	Korrektheit	65,8	69,8	70,2
	Vollständigkeit	62,0	62,9	62,1
	Qualität	46,9	49,4	49,1
<i>Bäume</i>	Korrektheit	95,7	95,7	95,6
	Vollständigkeit	93,9	94,6	94,4
	Qualität	90,0	90,7	90,5
<b>Mittelwert der Qualität</b>		79,6	80,6	80,6
<b>Gesamtgenauigkeit</b>		93,9	94,2	94,1

*Tabelle 14: Qualitätsmaße und Gesamtgenauigkeit in Prozent für Ansatz A (Höhenunterschiede + 3 direkte Nachbarn), Ansatz B (alle Interaktionsmerkmale + 3 zufällige Nachbarn), Ansatz C (Höhenunterschiede + 3 zufällige Nachbarn)*

Würde man nach der Gesamtgenauigkeit in den verschiedenen Ansätzen entscheiden, so würde man Ansatz B bevorzugen. Es zeigt sich, dass die Kombination der besten

## 4.6 Analyse einzelner CRF-Komponenten

---

Konfigurationen keine Verbesserung mit sich bringt. Hier sinkt die Gesamtgenauigkeit etwas (0,1%) gegenüber dem Ansatz mit allen Interaktionsmerkmalen und den drei zufälligen Nachbarn. Die besten Ergebnisse für die Klassifikation mit drei Nachbarn erhält man, wenn man die Nachbarn zufällig auswählt und alle Interaktionsmerkmale verwendet.

### 5 Zusammenfassung und Ausblick

Ziel der vorliegenden Arbeit war es zu untersuchen, inwieweit Kontextwissen die Ergebnisse der Klassifikation von Laserpunktwolken in einem städtischen Gebiet beeinflussen kann. Dazu wurden die kontextbasierten Verfahren MRF und CRF angewendet und als Referenzverfahren die SVM hinzugezogen, in denen jeder einzelne Punkt für sich betrachtet wird. Um die unterschiedlichen Verfahren am besten vergleichen zu können, wurden gleiche Testbedingungen geschaffen.

Mit Hilfe von Graphen lassen sich bei den kontextbasierten Verfahren Informationen darstellen und ihr Kontext modellieren. Im ersten Experiment (Kapitel 4.3) wurde für das Testgebiet Hannover die Anzahl der Nachbarn im Graphen auf drei festgelegt. Für den Entwurf der Graphen wurde der Ansatz kNN aufgrund der kürzeren Berechnungszeit ausgewählt.

Vor der Klassifikation mit den MRF und CRF wurde in Kapitel 4.4 zwischen unterschiedlichen Modellen für das Cliques- bzw. Interaktionspotential ausgewählt. Aufgrund der besseren Werte in der Gesamtgenauigkeit wurde für beide Potentiale das Modell des vollen Potentials gewählt. In diesem Modell werden unterschiedliche Gewichte für alle Klassenkombinationen angelernt und dadurch das Testgebiet besser beschrieben. Auch kleinere Details wie in der Klasse *Gebüsch* werden besser dadurch erhalten. Nur bei den CRF wirkte sich die Berechnungszeit für das Training bei dem Modell des vollen Potentials nachteilig aus. Bei den MRF wurde eine ähnliche Berechnungszeit wie beim Potts-Modell benötigt.

Nach den Vorbereitungen konnte der Vergleich zwischen SVM, MRF und CRF durchgeführt werden. Die besten Ergebnisse in der Gesamtgenauigkeit wurden wie erwartet mit den CRF (93,7%) erreicht. Aufgrund der Beschränkung des lokalen Kontext in den CRF, wurde für die MRF ein geringfügig schlechterer Wert (93,6%) erzielt. Die SVM erreichten die schlechteste Gesamtgenauigkeit mit 93,3%. Diese Verbesserungen in den kontextbasierten Verfahren ließen sich in der Qualität für die

Klassen *Bäume* und *Gebäude* deutlich machen. Dafür wurde in der Klasse *Gebüsch* mit den SVM der bessere Wert erreicht. Somit zeigt sich, dass Kontextwissen bei der Klassifikation von Laserpunktwolken eine Verbesserung in städtischen Gebieten mit sich bringt, in denen viele verschiedene Objekte dicht beieinander stehen. Bei der Berechnungszeit benötigten die SVM die meiste Zeit beim Training und Testen, danach folgten die CRF und MRF.

Im Kapitel 4.6 sollten einzelne Komponenten der CRF analysiert und festgestellt werden, ob sich dadurch Verbesserungen nachweisen ließen.

Hierbei wurde zunächst in Kapitel 4.6.1 festgestellt, dass durch die Auswahl der Höhenunterschiede als Interaktionsmerkmale eine Verbesserung in der Gesamtgenauigkeit um 0,2% gegenüber der Nutzung aller Interaktionsmerkmale erzielt werden konnte. Die Qualität für die Klasse *Gebäude* stieg um 1,1%, für die Klasse *Gebüsch* um 0,7% und die Klasse *Bäume* um 0,5%.

Des Weiteren wurde in Kapitel 4.6.2 gezeigt, dass die Erhöhung der Anzahl der Nachbarn von drei auf sieben, auf zehn, 15, 20 und 40 für die CRF eine Verschlechterung ergab. Der beste Mittelwert für die Gesamtgenauigkeit konnte weiterhin mit drei Kanten erreicht werden.

Durch die Auswahl von drei zufällig gewählten Nachbarn, anstatt drei direkten Nachbarn für den Graphen, wurde in Kapitel 4.6.3 bestätigt, dass eine Steigerung um 0,5% in der Gesamtgenauigkeit erreicht werden konnte. Besonders die Qualität für die Klasse *Gebüsch* stieg um 3,2%, für die Klasse *Gebäude* um 2,2% und für die Klasse *Bäume* um 1,2%.

Die Kombination aus den beiden besten Konfigurationen in Kapitel 4.6.4 zeigte, dass keine Verbesserung in der Gesamtgenauigkeit erzielt werden konnte. Weiterhin wird mit drei zufälligen Nachbarn und allen Interaktionsmerkmalen die beste Gesamtgenauigkeit für das Testgebiet Hannover erzielt.

Im Hinblick auf die zukünftigen Entwicklungen der kontextbasierten Verfahren, könnte es aufgrund der guten Klassifikationsergebnisse in den SVM interessant sein,

anstatt der linearen Modelle die SVM für die Modellierung der Potentiale zu nutzen. Eine weitere Entwicklung wäre es, wenn für die CRF globaler Kontext von Klassen und Daten anstatt lokaler Kontext genutzt wird. Außerdem könnte die Nutzung multiskalarer Merkmale interessant sein. Bei diesen werden Punkte für die Berechnung der Merkmale aus unterschiedlichen Entfernungen ausgewählt. Durch die unterschiedlichen Entfernungen könnten dann Rückschlüsse auf die Anordnung der unterschiedlichen Objekte gezogen werden.



---

## Literaturverzeichnis

- [Baltsavias 1999]: E. Baltsavias: Airborne laser scanning: basic relations and formulas, *ISPRS Journal of Photogrammetry and Remote Sensing* 54, S. 199-214, 1999
- [Bishop 2006]: C. M. Bishop: Pattern recognition and machine learning, 1. Ausgabe, Springer New York, USA, 2006
- [Burgess 1998]: C. J. C. Burgess: A tutorial on support vector machines for pattern recognition, *Data Mining and Knowledge Discovery* 2, S. 121-167, 1998
- [Chang 2012] LIBSVM - A Library for Support Vector Machines, C. Chang, C. Lin, Version April 2012, <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>
- [Cheheta 2009]: N. Cheheta, L. Guo, C. Mallet: Airborne lidar feature selection for urban classification using random forests, *IntArchPhRS* 38(3), S. 207-212, 2009
- [Duda 2001]: R.O. Duda, P.E. Hart, D.G. Stork: Pattern classification, 2. Ausgabe, Wiley & Sons, New York, USA, 2001
- [Flood 2001]: M. Flood: Laser altimetry: from science to commercial lidar mapping, *Photogrammetry Engineering and Remote Sensing* 67(11), S. 1209-1217, 2001
- [Frey 1998]: B. Frey, D. MacKay: A revolution: belief propagation in graphs with cycles, *Advances in Neural Information Processing Systems*, Vol. 10, S. 479-485, 1998
- [Gross 2006]: H. Gross, U. Thoennessen: Extraction of lines from laser point clouds, *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 36 Part 3A, Bonn, S. 87-91, 2006
- [Gross 2007]: H. Gross, B. Jutzi, U. Thoennessen: Segmentation of tree regions using data of full-waveform laser, *ISPRS Conference Photogrammetric Image Analysis (PIA)*, Vol. 36, *IntArchPhRS*, München, 2007
- [Gualtieri 1998]: J. A. Gualtieri, R.F. Cromp: Support vector machines for hyperspectral remote sensing classification, *Proceedings of the 27th AIPR Workshop: Advances in Computer Assisted Recognition*, Washington DC, S.221-232, 1998
- [Heipke 1997]: C. Heipke, H. Mayer, C. Wiedemann, O. Jamet: Evaluation of automatic road extraction, *Int'l Arch. Photogrammetry Remote Sensing* XXXII/3-3W2, S. 151-160, 1997

- 
- [Heipke 2011]: C. Heipke, Vorlesung Methoden der Photogrammetrie und Fernerkundung, Institut für Photogrammetrie und GeoInformation, Leibniz Universität Hannover, 2011
- [Höfle 2007]: B. Höfle, N. Pfeifer: Correction of laser scanning intensity data: data and model-driven approaches, ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 62, Issue 6, S. 415-433, 2007
- [Hug 2004]: C. Hug, A. Ulrich, A. Grimm: Litemapper-5600 - A waveform-digitizing LIDAR terrain and vegetation mapping system, Volume 36 (Part8/W2), Freiburg, S. 24-29, 2004
- [Kschischang 2001]: F.R. Kschischang, B.J. Frex, H. Loeliger: factorgraphs and sum-product algorithm, IEEE Transactions on Information Theory, Vol. 47, No.2, 498-519, 2001
- [Mallet 2010]: C. Mallet: Analysis of full-waveform lidar data for urban area mapping, Ph.D. thesis, Télécom ParisTech, 2010
- [Mallet 2009]: C. Mallet, F. Bretar: Full-waveform topographic lidar: State-of-the-art, ISPRS Journal of Photogrammetry and Remote Sensing 64, S. 1-16, 2009
- [Niemeyer 2011]: J. Nimeyer, J.D. Wegner, C. Mallet, F. Rottensteiner, U. Sörgel: Conditional random fields for urban scene classification with full-waveform lidar data, International Archives of Photogrammetry, Remote Sensing and Spatial Information Science 38, 2011
- [Rottensteiner 2012]: F. Rottensteiner, Vorlesung Bildanalyse I+II, Institut für Photogrammetrie und GeoInformation, Leibniz Universität Hannover, 2012
- [Schmidt 2012]: Matlab Toolbox for undirected graphical models (UGM), M. Schmidt, Version Juli 2012, <http://www.di.ens.fr/~mschmidt/Software/UGM.html>
- [Vishwanathan 2006]: S. Vishwanathan, N. Schraudolph, M. Schmidt, K. Murphy: Accelerated training of conditional random fields with stochastic gradient methods, 23. International Conference on Machine Learning, S. 969-976, 2006
- [Wagner 2006]: W. Wagner, A. Ulrich, Ducic, T. Melzer, N. Studnicka: Gaussian decomposition and calibration of a novel small-footprint full-waveform digitising airborne laser scanner, ISPRS Journal of Photogrammetry and Remote Sensing 60(2), S. 100-112, 2006
- [Wegner 2011]: J.D. Wegner: Detection and height estimation of buildings from SAR and optical images using conditional random fields, Dissertation, Fakultät für Bauingenieurwesen und Geodäsie, Leibniz Universität Hannover, 2011

- 
- [Wehr 1999]: A. Wehr, U. Lohr: Airborne laser scanning - an introduction and overview, ISPRS Journal of Photogrammetry and Remote Sensing 54, S. 68-82, 1999
- [Wolf 2006]: L. Wolf, S. Bileschi: A critical view on context, International Journal of Computer Vision 69(2), S. 251-261, 2006

---

## Abbildungsverzeichnis

Abb. 2.1: Messprinzip nach [Heipke 2011].....	4
Abb. 2.2: Messeinheiten nach [Heipke 2011].....	4
Abb. 2.3: Vergleich diskrete und full-waveform Daten nach [Mallet 2010].....	6
Abb. 2.4: Amplitude, Echobreite, Echoanzahl nach [Mallet 2010].....	7
Abb. 2.5: Geometrie der Diskriminanzfunktion im zweidimensionalen Merkmalsraum nach [Bishop 2006].....	8
Abb. 2.6: Feature Space Mapping: Transformation einer Geraden (y) im 2D Merkmalsraum in eine Parabel im 3D Merkmalsraum. Die Ebene teilt den 3D Merkmalsraum in zwei Regionen nach [Duda 2001].....	9
Abb. 2.7: Hyperebene mit Abstand (margin), Klassen und Support Vectors.....	11
Abb. 2.8: Darstellung der Schlupfvariablen nach [Rottensteiner 2012].....	11
Abb. 2.9: links: Ungerichteter Graph, Mitte: Gerichteter Graph, rechts:Faktorgraph	15
Abb. 2.10: Graphenstruktur der MRF nach [Bishop 2006].....	17
Abb. 2.11: Graphenstruktur der CRF nach [Bishop 2006].....	20
Abb. 3.1: Graphenstruktur einer Punktwolke mit zylindrischer Umgebung nach [Niemeyer 2011].....	23
Abb. 4.1: Luftbilder der drei Gebiete (Hannover 1 - oben, Hannover 2 - Mitte, Hannover 3 - unten) [Google Maps].....	31
Abb. 4.2: Referenzpunktwolke der drei Gebiete (gelb-Boden, magenta-Gebäude, blau-Gebüsch, grün-Bäume).....	31
Abb. 4.3: Mittelwert der Gesamtgenauigkeiten.....	33
Abb. 4.4: Berechnungszeit für das Training.....	33
Abb. 4.5: Referenzdaten (MRF).....	37
Abb. 4.6: Klassifikation mit Potts-Modell (MRF).....	37
Abb. 4.7: Klassifikation mit Modell des vollen Potentials (MRF).....	37
Abb. 4.8: Klassifikation mit erweitertem Potts-Modell (MRF).....	37
Abb. 4.9: Referenzdaten.....	41
Abb. 4.10: Klassifikation SVM.....	41
Abb. 4.11: Klassifikation MRF.....	41
Abb. 4.12: Klassifikation CRF.....	41
Abb. 4.13: Referenzdaten.....	43
Abb. 4.14: Klassifikation SVM.....	43
Abb. 4.15: Klassifikation MRF.....	43
Abb. 4.16: Klassifikation CRF.....	43
Abb. 4.17: Luftbild des gezeigten Gebietes [Bing Maps].....	43
Abb. 4.18: Referenzdaten.....	47
Abb. 4.19: Klassifikation mit allen Interaktionsmerkmalen .....	47
Abb. 4.20: Klassifikation mit Höhen- und Amplitudenunterschieden.....	47
Abb. 4.21: Klassifikation mit Höhenunterschieden.....	47
Abb. 4.22: Mittelwert der Qualität für die einzelnen Klassen in Prozent.....	49
Abb. 4.23: Zylinderradius von ungefähr 26,4m im Testgebiet.....	51
Abb. 4.24: Referenzdaten.....	53

Abb. 4.25: Ansatz A: 3 direkte Nachbarn.....53  
Abb. 4.26: Ansatz B: 3 zufällige Nachbarn.....53  
Abb. 4.27: Ansatz C: 1 direkter und 2 zufällige Nachbarn.....53

## Tabellenverzeichnis

Tabelle 1: Verteilung der Objektklassen in den Testgebieten.....	31
Tabelle 2: Qualitätsmaße und Gesamtgenauigkeit in Prozent für Ansatz kNN und Ansatz zylindrische Umgebung (Zylinder) sowie deren Differenz.....	34
Tabelle 3: Berechnungszeit Ansatz kNN und Ansatz Zylinder.....	35
Tabelle 4: QualitätsmaßSe und Gesamtgenauigkeit in Prozent für die unterschiedlichen Modelle des Cliquenpotentials (MRF).....	36
Tabelle 5: Qualitätsmaße und Gesamtgenauigkeit in Prozent für die unterschiedlichen Modelle des Interaktionspotetials (CRF).....	38
Tabelle 6: Berechnungszeit der verschiedenen Modelle für die MRF.....	39
Tabelle 7: Berechnungszeit der verschiedenen Modelle für die CRF.....	39
Tabelle 8: Qualitätsmaße und Gesamtgenauigkeit in Prozent für die Ergebnisse von SVM, MRF, CRF.....	40
Tabelle 9: Anzahl der Punkte pro Gebiet und für das Training sowie Berechnungszeit für das Training und Testen für die jeweiligen Gebiete.....	44
Tabelle 10: Qualitätsmaße und Gesamtgenauigkeit in Prozent für CRF mit allen Interaktionsmerkmalen, mit Höhenunterschieden oder mit Höhen- und Amplitudenunterschieden.....	46
Tabelle 11: Gesamtgenauigkeit und Mittelwert der Qualität der unterschiedlichen Anzahl an Nachbarn in Prozent.....	49
Tabelle 12: Qualitätsmaße und Gesamtgenauigkeit in Prozent für Ansatz A (3 direkte Nachbarn), Ansatz B (3 zufällige Nachbarn) und Ansatz C (1 direkter und 2 zufällige Nachbarn).....	52
Tabelle 13: Qualitätsmaße und Gesamtgenauigkeit in Prozent für 5 direkte und 5 zufällige Nachbarn.....	54
Tabelle 14: Qualitätsmaße und Gesamtgenauigkeit in Prozent für Ansatz A (Höhenunterschiede + 3 direkte Nachbarn), Ansatz B (alle Interaktionsmerkmale + 3 zufällige Nachbarn), Ansatz C (Höhenunterschiede + 3 zufällige Nachbarn).....	56