



Institut für Photogrammetrie

---

**Semantik-basierte Gebäudeerfassung mit  
verkoppelten Markoff-Zufallsfeldern**

**Inaugural-Dissertation**

zur

Erlangung des Grades

Doktor-Ingenieur (Dr.-Ing.)

der

Hohen Landwirtschaftlichen Fakultät

der

Rheinischen Friedrich-Wilhelms-Universität

zu Bonn

Vorgelegt am 28. Juni 2000 von

**Dipl.-Ing. Ansgar Brunn**

aus Brakel (Krs. Höxter)

---

---

Referent:

1. Korreferent:

2. Korreferent:

Prof. Dr.-Ing. Wolfgang Förstner

Prof. Dr.-Ing., Dr.-Ing. E.h. mult. Karl-Rudolf Koch

Prof. Dr. Bernd Neumann

Tag der mündlichen Prüfung:

Gedruckt bei:

---

# Semantik-basierte Gebäudeerfassung mit verkoppelten Markoff-Zufallsfeldern

Dipl.-Ing. Ansgar Brunn

## Kurzfassung

In dieser Arbeit wird ein neues automatisches Verfahren zur Erfassung von Gebäuden aus Digitalen Oberflächenmodellen entwickelt. Im Gegensatz zu den meisten bisher in der Literatur beschriebenen Verfahren wird in diesem Ansatz die Rekonstruktion der Gebäude eng mit der Interpretation verknüpft. Es wird ein topologischer Ansatz zur Gebäuderekonstruktion gewählt, der die integrierte Auswertung von unterschiedlichen Datenquellen ermöglicht.

Die Topologie eines Objektes lässt sich durch einen CW-Komplex repräsentieren. In dieser Arbeit werden CW-Komplexe zur Repräsentation der Topologie der Gebäudeoberfläche genutzt. Die Bestandteile des CW-Komplexes, die Zellen (Punkte, Kanten und Flächen), werden lokal klassifiziert. Zur Verbesserung der lokalen Klassifikationen werden Nachbarschaftsbedingungen mittels bedingter Wahrscheinlichkeiten berücksichtigt. Dazu wird eine Nachbarschaftsordnung auf dem CW-Komplex definiert und ein verkoppeltes Markoff-Zufallsfeld formuliert. Wir lernen die Gebäudemodelle automatisch aus repräsentativen Interpretationen. Die Gebäude werden lokal -aufgrund der Klassifikation der Zellen - mittels robuster Schätzverfahren rekonstruiert. Die Gebäudetypen der rekonstruierten Gebäude werden durch das Markoff-Zufallsfeld klassifiziert.

Zur Veranschaulichung des Potentials und Beurteilung des Verfahrens werden synthetische und reale Beispiele in einem verallgemeinerten geometrischem Modellraum angeführt und diskutiert.

---

# Semantic-based Building Acquisition with Coupled Markov-Random-Fields

## **Abstract**

The thesis develops a new automatic algorithm for the acquisition of buildings from digital surface models. In contrast to most of the already published techniques, the new algorithm closely combines the reconstruction with the interpretation. We choose a building representation based on its topology, which enables a combined evaluation of different sensor types.

We use CW-complexes for the topological building representation. The elements of the CW-complexes, the cells, are classified locally. We take neighborhood relations into account by conditional probabilities to improve the classification result. Therefore we define a neighborhood system on the CW-complex and build a Markov-Random-Field. We automatically learn building models from representative examples. The buildings are reconstructed locally using the classification result. By calculation of various building reconstructions using distinct building models, a classification of the type of the complete building is done.

Establishing a reduced building model, we discuss synthetic and real examples to show the capabilities of the new algorithm. The importance of the approach is shown by the examples.

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>9</b>
1.1	Allgemeines . . . . .	9
1.2	Gebäuderekonstruktion . . . . .	11
1.3	Oberflächen . . . . .	14
1.3.1	Repräsentation von Oberflächen . . . . .	14
1.3.2	Gewinnung von Oberflächendaten . . . . .	15
1.3.2.1	Bilddaten . . . . .	15
1.3.2.2	Laserdaten . . . . .	15
1.4	Zufallsfelder . . . . .	17
1.5	Ziel des Verfahrens . . . . .	18
1.6	Übersicht über die Arbeit . . . . .	19
<b>2</b>	<b>Theoretische Grundlagen</b>	<b>21</b>
2.1	Topologie triangulierter Polyederoberflächen . . . . .	21
2.1.1	Polyederoberflächen . . . . .	21
2.1.2	Topologische Komplexe . . . . .	23
2.2	Zufallsfelder . . . . .	25
2.2.1	Das Bayes-Theorem . . . . .	25
2.2.2	Formulierung des Zufallsfeldes . . . . .	25
2.2.3	Markoff-Zufallsfelder . . . . .	26
2.2.4	Verkoppelte Markoff-Zufallsfelder . . . . .	29
2.2.5	Lösungsverfahren . . . . .	29
2.2.5.1	Lokale Lösungsverfahren . . . . .	29
2.2.5.2	Globale Lösungsverfahren . . . . .	30
2.2.6	Beurteilung der Klassifikationsergebnisse . . . . .	31
2.3	Parameterschätzung und Modellklassifikation . . . . .	32
2.3.1	Das Gauss-Markoff-Modell . . . . .	32
2.3.2	Parameterschätzung mit Restriktionen . . . . .	33
2.3.3	Das gemischte Schätzmodell . . . . .	33
2.3.4	Beurteilung von Schätzern . . . . .	34
2.4	Beschreibungslänge . . . . .	35
2.5	Robuste Schätzung . . . . .	36
<b>3</b>	<b>Interpretation und Rekonstruktion von Gebäuden</b>	<b>37</b>
3.1	Das Gebäudemodell . . . . .	38
3.1.1	Allgemeines Objektmodell . . . . .	39
3.1.2	Das semantische Gebäudemodell . . . . .	40
3.1.3	Statistisches Gebäudewissen . . . . .	41
3.1.4	Lernen von bedingten Wahrscheinlichkeiten . . . . .	44
3.1.5	Likelihoodwissen . . . . .	45
3.2	Strategie des Verfahrens . . . . .	47
3.3	Das Klassifikationsproblem . . . . .	48

3.4	Das Rekonstruktionsproblem . . . . .	49
3.5	Klassifikation der Gebäudetypen . . . . .	50
<b>4</b>	<b>Gebäudeextraktion aus Laserdaten</b>	<b>51</b>
4.1	Modellbildung . . . . .	51
4.2	Die Näherungsoberfläche . . . . .	55
4.2.1	Extraktion von Strukturelementen der Oberfläche . . . . .	58
4.2.2	Generierung einer 3D Gebäudebeschreibung . . . . .	59
4.3	Klassifikation . . . . .	60
4.3.1	Lösungsalgorithmen des MRFs . . . . .	60
4.3.2	Beobachtungen . . . . .	61
4.3.3	Initialisierung . . . . .	61
4.3.3.1	Klassifikation von Knoten . . . . .	61
4.3.3.2	Klassifikation von Kanten . . . . .	63
4.3.3.3	Klassifikation von Dreiecken . . . . .	63
4.3.4	Behandlung des Randes . . . . .	64
4.4	Rekonstruktion . . . . .	65
4.4.1	Charakterisierung der Schätzprobleme . . . . .	65
4.4.2	Übersicht über die Schätzer . . . . .	65
4.4.3	Die Schätzmodelle im Einzelnen . . . . .	66
4.4.3.1	Punktschätzer . . . . .	66
4.4.3.2	Kantenschätzer . . . . .	67
4.4.3.3	Dreiecksschätzer . . . . .	67
4.4.4	Robuste Schätzung . . . . .	68
4.4.5	Behandlung des Randes in der Rekonstruktion . . . . .	68
<b>5</b>	<b>Ergebnisse der Realisierung</b>	<b>69</b>
5.1	Synthetisches Beispiel . . . . .	69
5.2	Reale Daten . . . . .	78
5.2.1	Vorverarbeitung . . . . .	78
5.2.2	Klassifikation und Rekonstruktion . . . . .	80
5.3	Vergleich der beiden Lösungsverfahren des MRFS . . . . .	84
5.4	Beurteilung des Rekonstruktionsergebnisses . . . . .	89
<b>6</b>	<b>Zusammenfassung und Ausblick</b>	<b>91</b>
6.1	Zusammenfassung . . . . .	91
6.2	Ausblick . . . . .	91
<b>A</b>	<b>Unsichere Repräsentationen und die Fortpflanzung von Kovarianzen</b>	<b>95</b>
A.1	Das Fehlerfortpflanzungsgesetz . . . . .	95
A.2	Repräsentation einfacher unsicherer geometrischer Objekte . . . . .	96
A.2.1	Punkte . . . . .	96
A.2.2	Geraden . . . . .	96
A.2.3	Dreiecke in 3D . . . . .	97
A.2.4	Richtungsvektoren . . . . .	97
A.3	Ableitung von Winkeln aus Richtungsvektoren . . . . .	97
A.4	Fehlerfortpflanzung für Vektoren . . . . .	98
A.5	Ebenen . . . . .	99
A.5.1	Unsichere Ebenen . . . . .	100
A.5.2	Direkte Lösung . . . . .	100
A.5.3	Mittelung von zwei Ebenennormalenvektoren . . . . .	101

<b>B</b>	<b>Notationen und Legende</b>	<b>103</b>
B.1	Allgemeines . . . . .	103
B.2	Statistische Größen . . . . .	103
B.2.1	Klassifikation . . . . .	103
B.2.2	Parameterschätzung . . . . .	103
B.3	Geometrische Größen . . . . .	104
B.4	Topologische Größen . . . . .	104
B.5	Legende zu den Abbildungen . . . . .	104
<b>C</b>	<b>Abkürzungsverzeichnis</b>	<b>105</b>
C.1	Klassen der Gebäudeteile . . . . .	105
C.1.1	Semantisches Modell . . . . .	105
C.1.2	Geometrisches Modell . . . . .	105
C.2	Weitere Abkürzungen . . . . .	106
	<b>Literatur</b>	<b>111</b>





# Kapitel 1

## Einleitung

### 1.1 Allgemeines

Die hochaktuelle Kenntnis unserer Umgebung gewinnt in den letzten Jahren immer mehr an Bedeutung. Insbesondere die Erfassung der Situation in bebauten Gebieten ist für Planungsvorhaben und Analyse Zwecke unabdingbar. Auf Gebäude als wesentliche Bestandteile der Stadtlandschaft wird dabei besonderer Wert gelegt.

Diese Arbeit ist durch den in den letzten Jahren beständig steigenden Bedarf an vor allem dreidimensionalen Gebäudedaten motiviert. Private wie öffentliche Organisationen stellen hohe Anforderungen an die Verfügbarkeit und Aktualität von 3D Stadtdateien. Anwendungen wie Stadtplanung, der Bau von Telekommunikationseinrichtungen, Flottenmanagement und Strömungssimulationen für Umweltverträglichkeitsprüfungen stellen aktuelle Fragestellungen dar, die zuverlässiges Datenmaterial erfordern. Die Anwendungen bedürfen eines aktuellen Informationssystems zur situationsangepassten und aktualitätsbezogenen Planung oder Analyse.

Zur Zeit verfügbare Erfassungsmethoden sind nicht in der Lage, diese Anforderungen in dem gewünschten Detaillierungsgrad kostengünstig und jederzeit aktuell zu erfüllen, da sie zumeist nur automationsunterstützt oder gar manuell sind. Um für die jeweilige Anwendung einen hohen Aktualitätsgrad und eine einfache Verfügbarkeit der Daten zu gewährleisten, müssen neue Verfahren unter Ausnutzung einer weitgehenden Automatisierung entwickelt werden, insbesondere auch, da in einigen Planungsbereichen schon über die Automation der nicht nur ordnungsrechtlichen Planungsteile nachgedacht wird: z. B. entwickeln AVERDUNG UND LUTTERBACH 1995 ein System zur automatischen bodenordnerischen Planung. Die vorliegende Arbeit zeigt einen Schritt auf dem Weg zur Automatisierung der Erfassung auf und stellt ein Verfahren zur automatischen Rekonstruktion und Interpretation von Gebäudedaten vor.

Die Anforderungen an drei-dimensionale Daten werden von unterschiedlichen Anwendungen gestellt und unterliegen einer ständigen Veränderung. Aktuelle Erfassungssysteme sind zu anwendungsspezifisch, als dass sie einer Vielzahl von Anwendungen gerecht werden könnten. Hier bedarf es einer möglichst anwendungsunabhängigen Modellierung. Dieses ist in dieser Arbeit eine Motivation für die Verwendung einer semantischen Modellierung.

Zwei prinzipielle Ansätze der Rekonstruktion werden in der Literatur unterschieden: Der flächenhafte Ansatz zielt auf eine Gesamtrekonstruktion aller Gebäude einer Stadtlandschaft ab. Dabei werden unterschiedliche Gebäude nicht voneinander getrennt. Der andere Ansatz fokussiert auf einzelne Gebäude und rekonstruiert diese, um zu dem gleichen Rekonstruktionsergebnis zu gelangen.

Beide Ansätze sind als einstufige oder mehrstufige Verfahren realisiert worden. Im einstufigen Verfahren wird eine global verfügbare Eigenschaft der Objekte verwandt. Für die mehrstufigen Verfahren werden i. d. R. die drei Schritte "Detektion", "Rekonstruktion" und "Interpretation" unterschieden: Im ersten Schritt grenzt das Verfahren einzelne Objekte oder Objektteile aus, die

dann im zweiten Schritt einzeln rekonstruiert und im dritten Schritt interpretiert werden<sup>1</sup>.

Vergleicht man den einstufigen mit dem mehrstufigem Ansatz, stellt man fest, dass der dreistufige Ansatz eine genauere Objektmodellierung erfordert, da die Auswerteschritte differenzierter sind. Es genügen jedoch eine Modellierung von Teilstrukturen (einzelner Gebäude oder Gebäudeteile) des Objektes und Vorschriften für deren Verknüpfung als Modellwissen.

Aktuelle Erfassungsmethoden konzentrieren sich auf die Erfassung der Geometrie der Gebäude. Automatische Methoden zielen bisher nicht auf eine semantische oder funktionale Interpretation der Gebäude oder Gebäudeteile. Teilweise verwenden sie jedoch semantisches Wissen (FISCHER *et al.* 1999). Bei halbautomatischen Verfahren wird die Interpretation teilweise durch den Beobachter übernommen. Die Interpretationsfähigkeit der automatischen Verfahren ist neben der Kostenreduktion eine wesentliche Voraussetzung für die Akzeptanz dieser neuen Techniken, da nachfolgende Verarbeitungsschritte dann auf einzelne Aspekte oder Teile der Rekonstruktion optimiert werden können. Gleichzeitig kann durch die Interpretation die Rekonstruktion aufgrund von zusätzlichem Vorwissen gesteuert und verbessert werden.

In dieser Arbeit wird ein Verfahren vorgestellt, das eine abstrakte topologische Gebäudebeschreibung wählt und so in der Lage ist, unterschiedliche Datenquellen in die Auswertung zu integrieren. Dieses neue Verfahren liefert als Ergebnis rekonstruierte und interpretierte Gebäude.

Zweck dieser Arbeit ist es also einerseits ein multisensorielles Verfahren zur Gebäuderekonstruktion vorzustellen, andererseits aber auch zu evaluieren, was mit einem Ansatz, der auf lokalen Strukturen basiert, in der Gebäuderekonstruktion, insbesondere unter Ausnutzung der Technik der Laserscannerdaten, erreicht werden kann.

Zur Rekonstruktion von 3D Stadtlandschaften werden bisher im wesentlichen Bilder, Karten oder Geodaten als Datenmaterial verwendet (s. Abs. 1.2). Direkt mittels Laserscannern gemessene Digitale Oberflächenmodelle gewinnen im Augenblick zunehmend an Bedeutung. Oberflächenmodelle mit geringer Auflösung ( $> 1m^2$ ) waren als Resultat der automatischen Generierung aus Stereoluftbildern bekannt (KRZYTEK 1991). Seit kurzer Zeit stehen jedoch auch hochaufgelöste Oberflächenmodelle mit einer Bodenauflösung unter  $0.36m^2$  zur Verfügung, die neue Möglichkeiten der Automation, auch für die Datenfusion eröffnen (ACKERMANN 1999). Ebenso die Möglichkeit in Wäldern die Erdoberfläche zu beobachten, eröffnet neue Anwendungsfelder und löst Probleme der bisherigen Verfahren.

Die Rekonstruktion von Gebäuden auf der Basis von mit Laserscannern gemessenen dichten Digitalen Oberflächenmodellen ist exemplarisch realisiert worden. Das allgemeine Interesse an der Verwendung von Laserdaten ist im Augenblick sehr groß, was sich auch in den Ergebnissen der ersten Phase des "OEEPE Project on Laser Data Acquisition" ablesen lässt (AXELSSON UND PETZOLD 1999). 50 % der Firmen, die an dem Test teilgenommen haben, nutzen Laserdaten. Von diesen wiederum zwei Drittel integrieren die Laserdaten bereits in die Produktion. Als Gründe für die Nutzung der Laserdaten werden die hohe Punktdichte, hohe Präzision, die hohe Glaubwürdigkeit und die Möglichkeit der Behandlung von Vegetation angegeben.

Die aktuellen Anforderungen an drei-dimensionale Gebäudedaten erfordern trotz schon mehr als zehnjähriger Forschung im Bereich der automatischen Gebäuderekonstruktion weiterhin die Verbesserung bestehender und die Entwicklung neuer Verfahren. Dabei ist durch die Modellierung der Gebäude auf semantischer Ebene eine Vergrößerung der Anwendungsfelder und eine Verbesserung der Verfahren zu erwarten. Die Loslösung von der geometrie-bezogenen Modellierung ist der erste wichtige Schritt. Die Modellierung der Bedeutungen und Funktionen der Objekte führt auf die in dieser Arbeit eingeführte topologische Gebäuderepräsentation. Die Entwicklung eines ersten Verfahrens, das auf dieser topologischen Repräsentation unter Berücksichtigung multisensorieller Daten operiert, ist für die Akzeptanz der semantik-basierten automatischen Rekonstruktionsverfahren wichtig. Die gemeinsame, gleichwertige Behandlung der unterschiedlichen semantischen Teile eines Gebäudes ist dazu erforderlich. Im Gegensatz zu bisherigen, sequentiellen Verfahren ist dazu ein parallelisierbarer Algorithmus notwendig. Die Nutzung verkoppelter Markoff-Zufallsfelder bietet sich hier an.

Das vorgeschlagene Verfahren wird im nächsten Abschnitt zunächst in den aktuellen Stand der

<sup>1</sup>Der dritte Schritt unterbleibt jedoch in den Fällen, wo eine geometrische Beschreibung des Gebäudes ausreicht.

Forschung in bezug auf die Rekonstruktionsverfahren eingeordnet. Danach wird auf das zugrundegelegte Datenmaterial sowie auf die Markoff-Zufallsfelder als zentrale Problemrepräsentation eingegangen.

## 1.2 Gebäuderekonstruktion

Die Rekonstruktion von einzelnen Gebäuden und die Rekonstruktion von Stadtlandschaften nimmt in der Literatur über Aerophotogrammetrie einen großen Anteil ein. Einige Konferenzen beschäftigen sich ausschließlich mit diesem Thema. Dementsprechend groß ist die Anzahl der vorgeschlagenen Erfassungsmethoden. In dieser Arbeit werden ausschließlich die Verfahren behandelt, die mit digitalen oder digitalisierten Daten arbeiten. Die Erfassungsmethoden, die analoge Bilder mit Automationsunterstützung nutzen, werden nicht betrachtet.

Gebäudeerfassungsmethoden lassen sich nach der Art der Objektrepräsentation und nach der Art des Erfassungsverfahrens unterscheiden (GÜLCH UND MÜLLER 1998). Weitere Unterscheidungskriterien bestehen in dem Typ der verwandten Daten, die jedoch wiederum eng mit den Erfassungsmethoden verknüpft sind, und den Einschränkungen in der Modellierung des natürlichen Objektes "Gebäude" (*closed-world-assumption*).

**Datenmaterial und Erfassungsverfahren:** Eine Trennung zwischen automatischen und halbautomatischen Verfahren zur Erfassung von Gebäuden ist schwer möglich. Die Verfahren unterscheiden sich in ihrer Automation graduell in den notwendigen Beiträgen eines menschlichen Beobachters und in den Annahmen über Leistungen von Vorverarbeitungsschritten. In dieser Arbeit werden die Verfahren erwähnt, die grundsätzlich Teil eines vollautomatischen Systems sein könnten.

Es werden sowohl terrestrische Aufnahmen und Luftbilder, als auch Digitale Oberflächenmodelle und Karten oder Geodatenbanken verwendet<sup>2</sup>. Eine Motivation für die Vielfalt der Arbeiten zeichnet sich durch die unterschiedlichen Kombinationen von Datensätzen aus. Verfahren, die primär auf Informationen aus Karten und Geodatenbanken basieren, sollen hier jedoch nicht berücksichtigt werden, da die Betrachtung der Vektorisierungstechniken und der Verfahren zur Interpretation von vektorisierten Datensätzen eine eigene Arbeit füllen würden. Die folgenden ausgewählten Beispiele für Rekonstruktionsverfahren sollen die Vielfalt der verwandten Verfahren verdeutlichen.

- **Bilder:** Erste Veröffentlichungen zur Rekonstruktion von Gebäuden nutzen extrahierte Liniensegmente aus Bildern mit zusätzlichem Wissen über den Sonnenstand (HERMAN UND KANADE 1987) oder die Fluchtpunkte (HUERTAS UND NEVATIA 1988), um den Grundriss von rechtwinkligen Flachdachgebäuden zu bestimmen. Aus extrahierten Liniensegmenten wird über geometrische Gruppierung der Gebäudegrundriss abgeleitet. Die Dachstruktur war bei diesen Arbeiten noch nicht Ziel der Rekonstruktion. Gebäude beschränkten sich auf einfache geometrische Körper.

Aktuelle Entwicklungen der Gebäuderekonstruktion aus Luftbildern zielen auf eine vollständige 3D Beschreibung der Gebäude. Dabei ist die Gebäudehöhe nicht mehr nur Attribut, sondern es werden alle drei Lagekoordinaten gleichwertig behandelt. Komplexere Gebäudeformen, insbesondere Dachformen werden möglich. Grundlage ist die geometrische Beschreibung der 3D Gebäude, die über Punkte, Kanten oder Blobs bestimmt wird. MOONS *et al.* 1998 benutzt mehrere Bilder, aus denen ebenfalls Grauwertkanten extrahiert werden. Mittels dieser wird eine feinstrukturierte Objektmodellierung im 3D Raum mit Rückprojektion in die Bilder betrieben. FISCHER *et al.* 1998 und LANG 1999 verwenden zusätzlich Punkte und Blobs. Aus mehreren überlappenden Bildern abgeleitete polymorphe symbolische Bildbeschreibungen werden im Objektraum als Gebäudeteile gruppiert, die dann wiederum zu ganzen Gebäuden zusammengesetzt werden. HENRICSSON 1995, HENDRICKX *et*

<sup>2</sup>Einen guten Überblick über die Techniken der Gebäudeerfassung auf der Basis von Luftbildern gibt MAYER 1999.

*al.* 1997 und SCHMID UND ZISSERMAN 1997 nutzen Linienzuordnungsverfahren zur Rekonstruktion von 3D Gebäudekanten, die dann zu ganzen Gebäuden gruppiert werden. Zur Stützung der Zuordnung werden die Grauwerte oder Farbwerte in der Nachbarschaft der Kante herangezogen. Alle Ansätze verfolgen eine Strategie, die Hypothesen über das Objekt oder Teilstrukturen des Objektes generiert und diese dann in den Daten verifiziert. Es handelt sich um sequentielle Verfahren mit dem Ziel einer geometrische Rekonstruktion der Gebäude. FISCHER *et al.* 1998 und LANG 1999 nutzen semantisches Klassenwissen, um die Rekonstruktion zu steuern.

Daneben gibt es Ansätze, die unterschiedlichen Schritte der Gebäuderekonstruktion in einen formalen Prozess zu integrieren. Diese Arbeiten versuchen die Prozess orientierten Entwicklungen zu formalisieren. STILLA *et al.* 1997 verwendet dazu ein Produktionsnetz, das die Aggregation zwischen aus Bildern extrahierten Strukturen mittels Produktionsregeln beschreibt. KULSCHEWSKI 1999 beschränkt sich auf die Interpretation monokularer Bilder. Er verwendet extrahierte Segmente als Basisinformation für eine Propagation in einem Bayes-Netz. Im Gegensatz zu dem Ansatz von STILLA *et al.* 1997 ermöglicht die Modellierung im Bayes-Netz die Integration von unsicherem Wissen. Die Komplexität der Interpretation ist jedoch abhängig von der Güte der Segmentierung, was auf realen Szenen ohne Hinzunahme von bereits semantischem Wissen bisher nicht zufriedenstellend gelöst ist.

- **Digitale Oberflächenmodelle:** Digitale Oberflächenmodelle werden ebenfalls zur Rekonstruktion von Gebäuden verwendet. Hier setzen sich zunehmend die mittels Laserscannern erfassten Digitalen Oberflächenmodelle durch. Für Digitale Oberflächenmodelle mittlerer Auflösung detektiert WEIDNER 1997 Gebäude und rekonstruiert diese mittels einzelner parametrisierter oder prismatischer Modelle. HAALA 1996 detektiert Gebäude über geschlossene Höhenlinien des Digitalen Oberflächenmodells. Er beurteilt dann die Form und Kompaktheit der umschlossenen Fläche. Für hochaufgelöste Digitale Oberflächenmodelle wurde die Segmentierung in BRUNN UND WEIDNER 1998 beschrieben. VOSSELMANN 1999 und MAAS 1999 erreichen durch eine anschließende morphologische Dilatation auf der Segmentierung eine vollständige Gebäudebeschreibung. Aus den gefundenen Regionen werden dann die zugeordneten originalen Messpunkte zur modellbasierten Rekonstruktion verwandt. HUG UND WEHR 1997 verwenden gleichzeitig mit der Höhe gemessene Bildinformation zur Detektion von Gebäuden. Bei JAYNES *et al.* 1997B, JAYNES *et al.* 1997A erfolgt die Rekonstruktion mittels einer Klassifikation des Gebäudetypen und nachfolgender Feineinpassung der Gebäudeparameter in die Daten. HAALA UND BRENNER 1997 stützen die Detektion durch Karteninformation. HAALA UND ANDERS 1997 benutzen eine verallgemeinerte Dachflächenbeschreibung.

Die beschriebenen Techniken sind aufgrund ihrer Gebundenheit an die Geometrie von der Identifizierbarkeit der Geometrie in den Datensätzen abhängig. Eine Abstraktion von den Datensätzen ist zwar innerhalb des Gruppierungsprozesses möglich. Die Gruppierung bezieht aber vor Allem wieder geometrisches und radiometrisches Wissen über Gebäude ein.

Grundsätzlich ist die Modellierung des Gebäudes von dem verwandten Datentyp geprägt. Eine Ausnahme bilden hier die Arbeiten von LANG 1999, da hier geometrisches Klassenwissen als Restriktionen in den Rekonstruktionsprozess integriert wird. In der vorliegenden Arbeit wird eine Modellierung unabhängig vom verwandten Datentyp vorgestellt: die topologische Gebäudemodellierung. Die Nähe der Modellierung zu der semantischen Beschreibung der Gebäude ermöglicht eine allgemeinere, anwendungsunabhängigere Modellierung.

Ein zweites Kriterium zur Unterscheidung der Verfahren zur Gebäuderekonstruktion ist die *Objektrepräsentation*. Bisherige Gebäudeerfassungsmethoden beschränken sich auf den geometrischen Anteil der Erscheinung des Gebäudes. In dieser Arbeit sollen nur Objektrepräsentationen behandelt werden, die eine Repräsentation des Objekts in 3D oder zumindest in 2.5D ermöglichen. Die Objektrepräsentationen lassen sich in die folgenden Kategorien in Bezug auf ihre Anpassungsfähigkeit einteilen (nach FÖRSTNER UND GÜLCH 1997):

- spezielle Modelle: Es handelt sich um feste Muster von Gebäuden, die in der einfachen Fragestellung der Musterzuordnung benutzt wurden;
- parametrisierte Modelle (z. B. LANG UND SCHICKLER 1993): Parametrisierte Modelle haben eine festgelegte Struktur. Einzelne Parameter können verändert werden, um so eine Varianz der Form in diesen Parametern zu erreichen;
- generische Modelle: Realisierungen generischer Modelle werden aus einem Baukastensystem während der Rekonstruktion generiert und können daher eine hohe Komplexität annehmen. Es werden
  - generische Modelle fester Struktur mit freier Anzahl der Parameter (z. B. Polyedermodele) und
  - generische Modelle mit variabler Struktur (z. B. *Constructive-Solid-Geometry*(CSG)-Modelle).

unterschieden. Der Abtrennung dieser beiden Typen ist fließend, da sie sich nur durch die Komplexität der Metaregel zur Generierung der Modellinstanz unterscheiden.

Im Falle von speziellen Modellen genügt für den Objektzugriff das Merken des Gebäudetyps, der Lagekoordinaten und der Orientierung. Bei parametrisierten Modellen müssen zusätzlich die Parameter der Modellparametrisierung abgelegt werden.

Generische Modelle zeichnen sich durch einen hohen Grad an Variabilität und damit Anpassungsfähigkeit aus. Durch die große Vielfältigkeit ergeben sich große Anforderungen an die Erfassungsmethode zur Modellauswahl. Generische Modelle bedürfen einer Metaregel zur Kombination von Primitiven. Als Verknüpfungsregeln können die Verkantungsvorschriften einer Triangulation dienen oder auch die Mengenoperatoren einer CSG-Repräsentation (s. ENGLERT UND GÜLCH 1996).

Grundsätzlich wird die Repräsentation von Gebäuden aufgrund der aus der “Computational Geometry” und der Topologie bekannten Strukturen von den Autoren ähnlich gehandhabt. Einschränkungen der Anwendbarkeit der Verfahren ergeben sich selten aus der gewählten Repräsentation, da mit nur geringem zusätzlichen Aufwand die Repräsentation erweitert werden kann, wenn es notwendig ist. Einschränkungen der Anwendbarkeit resultieren eher aus den Gebäudemodellannahmen oder Restriktionen der Algorithmen. Eine minimale Repräsentation mit einer minimalen Anzahl von freien Parametern wird nicht angestrebt. Die direkte Interpretierbarkeit der Ergebnisse hat eine größere Bedeutung als eine optimale und effiziente Repräsentation und Speicherung.

Ein wichtiges Kriterium für die großflächige Anwendbarkeit der Verfahren ist die **Lernbarkeit des Modellwissens**. Werden komplexere Modelle für die Gebäuderekonstruktion und -interpretation verwandt (z. B. generische Modelle), müssen zulässige Unterräume des repräsentierbaren Raumes vorgegeben werden. Die Beschränkung dieser Modellräume sollte automatisch erfolgen können. Dazu sind Lernverfahren notwendig. ENGLERT 1997 hat systematisch erfasste Stadtlandschaften untersucht und Häufigkeiten lokaler Strukturen analysiert. Weiteres gelerntes Wissen über die Erscheinungsform von Gebäuden sind aus der Bildsegmentierung bekannt (z. B. KLONOWSKI UND KOCH 1997).

Die Zuordnung von Begrifflichkeiten zu den Erscheinungsformen ist dabei immer notwendig, da es zwischen der antropogenen Benennung der Objekte und dem Objekt selbst nur seltene und schwache natürliche Verbindungen gibt. Daher ist zu erwarten, dass auch in Zukunft, bei Beibehaltung der beschriebenen Modellierungsebene der Gebäude, nur überwachte Lernverfahren sinnvoll für die Gebäudeklassifikation einsetzbar sind.

Als weitere Kriterien zur Beurteilung von Gebäuderekonstruktionsverfahren können die **Tragfähigkeit des Ansatzes** für eine Vollautomation und die Nähe der Verfahren zu einer **Produktionsreife** herangezogen werden. Bis zu einer Vollautomation der Gebäuderekonstruktion müssen noch viele Probleme gelöst werden. Die Modellvielfalt aller Entwicklungen wie auch der Einsatzbereich sind sehr eingeschränkt. Gerade auch deshalb ist die Produktionsreife der automatischen Verfahren noch nicht erreicht. Dennoch bieten halbautomatische Systeme die Möglichkeit,

Automatismen bereits zweckmäßig in den Erfassungsprozess zu integrieren (MÜLLER 1998, GÜLCH *et al.* 1999).

Es sind nur wenige Vergleichsmöglichkeiten zwischen den Verfahren vorhanden, da es an einheitlichem Testmaterial und an einer einheitlichen Anwendung fehlt. Ausnahmen bilden der ISPRS-Test ASCONA (MASON *et al.* 1994), der aber schon 1994 durchgeführt wurde, und die Studien, die die Telekommunikationsunternehmen in Hinblick auf die Erfassung von 3D Stadtmodellen durchgeführt haben, deren Ergebnisse jedoch, wenn überhaupt, nur unvollständig veröffentlicht werden.

## 1.3 Oberflächen

Als Objektrepräsentationsform und als Datengrundlage in der Realisierung werden in dieser Arbeit Oberflächen verwandt. Dabei handelt es sich um 2D Flächen, die in den 3D Raum eingebettet sind<sup>3</sup>. In diesem Abschnitt wird zunächst die Repräsentation von Oberflächen und danach die Gewinnung von Oberflächendaten behandelt.

### 1.3.1 Repräsentation von Oberflächen

Diese Arbeit zielt auf die Entwicklung eines Verfahrens zur Rekonstruktion und Interpretation der Oberflächenbeschreibung von Gebäuden. Vor Beginn der Rekonstruktion und Interpretation muss über die Art der Oberflächenrepräsentation entschieden werden, da die Gebäudemodelle von der Art der Repräsentation abhängen.

In der Literatur werden zur Repräsentation von Oberflächen unter anderem die folgenden Repräsentationsformen verwandt:

	Eindeutigkeit der Oberfläche	Vollständigkeit der Oberfläche	Adaptivität	Komplexität
unregelm. vert. Punkte	–	–	+	–
Raster	+	+	–	+
Polyeder	+	+	+	0
Triangulation	+	+	+	+

Abbildung 1.1: Möglichkeiten der Repräsentation von Oberflächen.

- *Mengen unregelmäßig verteilter Punkte* sind Stützstellen der Oberfläche. Bei zweckmäßiger Wahl der Punkte kann durch eine Verbindung der Punkte durch Kanten aus den entstehenden Dreiecken oder Polygonen eine Oberfläche erzeugt werden. Die Verbindung der Punkte ist jedoch nicht eindeutig, wenn kein weiteres Verkantungskriterium eingeführt wird, so dass die geschlossene Oberfläche auch nicht eindeutig gegeben ist. Insbesondere für nicht glatte Oberflächen, wenn also Bruchlinien vorhanden sind, ist die Flächengenerierung schwierig (VAN DAMME UND ALBOUL 1997). Der Zugriff auf Punktnachbarschaften ist aufwendig, wenn keine hierarchischen Datenmodelle verwendet werden.
- Die *Rasterrepräsentation* beinhaltet die vollständige Oberfläche, bietet einen einfachen Zugriff auf die einzelnen Elemente. Diese Repräsentation hat jedoch eine geringe Adaptivität an die Daten.

<sup>3</sup>Diese Formulierung ist eine Spezialisierung einer  $m$ D-Gebäudebeschreibung, wobei dann nicht nur die geometrische Oberfläche gemeint ist, sondern die Oberfläche auch aus abstrakten weiteren Dimensionen (z. B. radiometrischen Dimensionen) bestehen kann. Es handelt sich also allgemein um eine  $m$ D-Fläche, die in einen  $n$ D-Raum eingebettet ist ( $m < n$ ). In Hinblick auf die Realisierung wird diese allgemeine Repräsentation auf den oben beschriebenen Spezialfall reduziert.

- *Polyederflächen* (s. Abs. 2.1.1) bieten eine gute Adaptivität an das Modell. Effiziente Zugriffstechniken auf Nachbarschaften sind vorhanden. Die Topologie wie auch die Oberfläche selbst sind wohl definiert.
- Im Gegensatz zu den Polyederflächen und als deren Spezialisierung haben *Triangulationen* (s. 2.1.1) eine einfachere Topologie. Gleichzeitig haben sie eine gute Flexibilität und Adaptivität an die zu repräsentierenden Objekte.

In dieser Arbeit werden alle beschriebenen Repräsentation verwandt:

- Die Digitalen Oberflächenmodelle werden in Rasterrepräsentation als Daten für die Generierung der Näherungsoberfläche eingeführt (s. Abs. 4.2).
- Die Merkmalsextraktion auf den Gradienten der Oberfläche berechnet unregelmäßig verteilte 3D Punkte. Zusätzlich zu den Punkten werden durch die Merkmalsextraktion jedoch noch Kanten aus den Gradienten der Digitalen Oberflächenmodelle extrahiert (s. Abs. 4.2.1).
- Die 3D Punkte des Resultats der Merkmalsextraktion werden unter Berücksichtigung der Gebäudebruchlinien trianguliert. Auf dieser abgeleiteten Triangulation wird dann die Rekonstruktion und Interpretation durchgeführt. (s. Kap. 4)
- Die rekonstruierten und interpretierten Triangulationen werden im Kapitel 3 in die allgemeinere Beschreibung der Polyederoberflächen eingebettet.

Werden verschiedene Repräsentationsformen von Oberflächen in einem Auswerteprozess verwandt, bedarf es, wie schon angedeutet, der Transformation der Repräsentationen. In dieser Arbeit wurden dazu Methoden eingesetzt, die durch den Anwendungsbereich "Rekonstruktion von Gebäuden" möglich werden, ohne allgemeine Verfahren zur Lösung dieser Transformationsproblematik anzugeben (s. Abs. 4.2).

## 1.3.2 Gewinnung von Oberflächendaten

### 1.3.2.1 Bilddaten

Manuell gemessene Digitale Oberflächenmodelle (DOMs) werden in der Praxis noch verwandt, insbesondere wenn das Digitalisieren der analogen Aufnahmen zu aufwendig ist. Für eine anschließende rechnergestützte automatische Rekonstruktion und Interpretation sind sie jedoch nicht sinnvoll verwendbar, da einerseits die Erfassung aufwendig ist und andererseits der Beobachter weitere Interpretationen schnell visuell vornehmen könnte.

Automatisch gerechnete Digitale Oberflächenmodelle aus Stereoaufnahmen werden seit Jahren benutzt (KRZYTEK 1991, BALTSAVIAS UND KÄSER 1999). Die Genauigkeit der abgeleiteten Höhen ist ungefähr 1:10000 der Flughöhe. Die Punktdichte ist dabei abhängig von der Textur auf der Oberfläche. Bei Verwendung von flächenbasierten Korrelationsverfahren (ROUX *et al.* 1997) oder auch bei einer Kombination der punktbasierten Verfahren mit den flächenbasierten Korrelationsverfahren haben die luftbildbasierten Verfahren weiterhin Relevanz.

Kenntnisse über die in den Stereobildern enthaltenen Objekte können ebenfalls die Bestimmung des Oberflächenmodells verbessern. Das führt dann zu einer modellgestützten Oberflächenbestimmung, was jedoch einer (Teil-)Interpretation der Daten entspräche. Gerade für Szenen, die natürliche Objekte enthalten, sind jedoch noch Probleme der Repräsentation und Erkennung zu lösen.

### 1.3.2.2 Laserdaten

Messungen eines flugzeuggetragenen Laserscanners ermöglichen die direkte Bestimmung der Geländeoberfläche durch Polares-Anhängen, wenn mittels zumeist differentiell GPS und/oder Inertial-Systemen die Position des Flugzeugs zu jedem Messzeitpunkt bekannt ist oder bestimmt

werden kann. Die Entfernung wird entweder durch Laufzeitmessung eines Impulses oder Phasenmessung bestimmt. Daher ergeben sich die Koordinaten eines gemessenen Punktes durch eine Funktion der Position des Lasers  $\mathbf{X}_o$ , der Orientierung des Lasers mit seiner Rotationsmatrix in das übergeordnete System (Landessystem)  $\mathbf{R}$  und der wahren Oberfläche  $\mathcal{O}$

$$\mathbf{x} = \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \phi(\mathbf{X}_o, \mathbf{R}, \mathcal{O}) + \boldsymbol{\eta} \quad (1.3.1)$$

Der Vektor  $\boldsymbol{\eta}$  modelliert das Messrauschen. Weitere Informationen zur Technik der Laserscanner können in WEHR UND LOHR 1999 gefunden werden.




Abbildung 1.2: Prinzip der Laserscannermessung bei Annahme eines fächerförmig messenden Laserscanners.

Wenn die Laserdaten nur als 3D Punktwolke oder als 3D Oberfläche vorliegen und keine Daten über die Aufnahmegeometrie bekannt sind, muss ein vereinfachtes Beobachtungsmodell angenommen werden (s. Abb. 1.3). Dann ergibt sich die vereinfachte Beobachtungsgleichung zu

$$z = \bar{\phi}(x, y, \mathcal{O}) + \eta \quad (1.3.2)$$

Handelt es sich um ein rasterbasiertes Oberflächenmodell, ergibt sich

$$z_{i,j} = \bar{\phi}(x_i, y_j, \mathcal{O}) + \eta \quad (1.3.3)$$

Durch den Unterschied zur realen Geometrie ergeben sich jedoch nach der Umrechnung in die parallele Betrachtungsweise Verdeckungseffekte. Dieses hat insbesondere Auswirkung auf die Beobachtbarkeit von gassenartigen Strukturen auf der Erdoberfläche. Darüber hinaus werden die Gebäudeseiten aufgeraut und in Abhängigkeit von der Messungsdichte abgeflacht. Bis ein Digitales Oberflächenmodell aus den zuerst unregelmäßig verteilten Höhendaten abgeleitet wird, werden Vorverarbeitungsverfahren bei den Firmen eingesetzt, die wenig oder gar nicht dokumentiert sind. Den nicht modellierten systematischen Effekten der Aufnahmegeometrie und der Vorverarbeitung kann hier nur durch eine Vergrößerung der Punktvarianzen Rechnung getragen werden.

Die Laserbefliegungen bieten die Möglichkeit, vollautomatisch Digitale Geländeoberflächen zu bestimmen, in einer Auflösung, die mit Luftbildern nur in gut texturierten Gebieten erreichbar ist. Insbesondere ist man bei dieser Art der Aufnahme unabhängig von der radiometrischen Struktur der Oberfläche, die für die automatischen Zuordnungsverfahren explizit oder implizit notwendig sind.

Laserscannermessungen werden für immer mehr Anwendungen herangezogen:

- Aufbau von Digitalen Höhenmodellen (HOSS 1997, KRAUS UND RIEGER 1999, VON HANSEN UND VÖGTLE 1999, KNABENSCHUH UND PETZOLD 1999, SEYFERT 1995),






Abbildung 1.3: Vereinfachtes Prinzip der Laserscannermessung.

- Beobachtung von Trassen von Hochspannungsleitungen (z. B. LOHR UND SCHALLER 1999, AXELSSON UND STERNER 1999 und WEVER 1999) und
- Beobachtung von Überflutungsgrenzen (LOHR 1998, BOLLWEG 1999).

Eine direkte Verknüpfung der Entfernungsmessungen mit einem bildgebenden Sensor ist möglich. HUG UND WEHR 1997 zeigte die Nützlichkeit dieser Vorgehensweise für die Gebäudedetektion.

Insgesamt kann festgehalten werden, dass die Laserscannertechnik ein Messverfahren mit großen Entwicklungsperspektiven für die Zukunft ist. Deshalb werden Laserdaten exemplarisch in dieser Arbeit als Datenmaterial verwandt. Insbesondere die Ergänzung der Entfernungsmessung mit Reflektions- und Bilddaten wird multisensorielle Ansätze der Auswertung erfordern. Der beschriebene Ansatz ermöglicht die Integration weiterer Datenquellen.

## 1.4 Zufallsfelder

Zufallsfelder haben sich in den letzten Jahren als ein Verfahren zur Lösung von Bezeichnungsproblemen (*engl. labeling*) etabliert. Insbesondere die Markoff-Zufallsfelder (MRF)<sup>4</sup> (s. Abs. 2.2) werden aufgrund ihrer Markoff-Eigenschaft zur Formulierung von Bezeichnungsproblemen wie Segmentierungs-, Interpretations- und Verknüpfungsproblemen verwendet.

Die mit MRF gelösten Problemstellungen zeichnen sich durch eine netzartige Strukturierung der Zufallsvariablen und symmetrische Abhängigkeiten zwischen den Zufallsvariablen aus. MRF werden im Wesentlichen auf Rastern eingesetzt.

Die Verwendung von Zufallsfeldern gliedert sich in zwei Schritte:

- die Formulierung des Zufallsfeldes (Modellierung) und
- die Suche nach einer optimalen Belegung der Zufallsvariablen (Lösung).

Die Belegung wird vielfach als Bezeichnung bezeichnet. Mit der Bezeichnung des mit einer Zufallsvariablen verbundenen Objektes (z. B. einem Segment oder einem Pixel) geht semantisch eine Klassifikation einher. Im folgenden wird daher zwischen dem Bezeichnungsprozess und der Klassifikation nicht unterschieden.

Im Bereich der Segmentierung von 2D Datensätzen ist den grundlegenden Entwicklungen von GEMAN UND GEMAN 1984 und BESAG 1986 eine große Zahl von Anwendungen der Segmentierung mit Markoff-Zufallsfeldern gefolgt. Neben der Segmentierung von Rastern wurden auch Zufallsvariablen für Regionengrenzen eingeführt (GEMAN UND GEMAN 1984, BUSCH 1992) oder komplexere Strukturen (MCCLURE 1981) gewählt. Unterschiedliche Typen von Zufallsvariablen

<sup>4</sup> *engl. Markov Random Field*

werden in verkoppelten Zufallsfeldern formuliert. Es folgten Arbeiten, die das zwei-dimensionale Klassifikationsproblem in einen interpretativen Kontext einbetteten (GEIGER UND YUILLE 1990, MODESTINO UND ZHANG 1991, KOCH 1995, KÖSTER 1995, KLONOWSKY 1999). In den bisher genannten Arbeiten wurden die Nachbarschaften a priori festgelegt.

WANG 1997 führte dann eine variable Nachbarschaftsstruktur am Beispiel der Regionensegmentierung ein, indem er abhängig vom aktuellen Klassifikationsergebnis den Nachbarschaftsgraphen der Umgebung eines zu klassifizierenden Knotens erst kurz vor der Klassifikation über Zusammenhangskomponenten (*engl. connected components*) erzeugt.

Bei der Interpretation einer 2D Segmentierung handelt es sich um ein Benennungsproblem, was aber einen Spezialfall einer Segmentierung darstellt, da Zufallsvariablen klassifiziert werden, jedoch i. A. nicht zusammengefasst werden. Kösters Arbeiten (KÖSTER 1995) zeigen, dass es für die Interpretation von Luftbildern schwierig ist, objektive und über einen Maßstab und eine Szene hinaus gültige Kriterien anzugeben. Gerade die Rückkopplung der Benennung mit der vorverarbeitenden Segmentierung des Bildes ist notwendig. KLONOWSKY 1999 deutet die Möglichkeiten der Verkopplung an. KIM UND YANG 1996 interpretieren natürliche terrestrische Bildszenen mittels einer Grauwertsegmentierung. Die Interpretation wird ebenfalls durch semantisches Wissen unterstützt.

Ein weiteres Anwendungsfeld, in dem zunehmend mit Zufallsfeldern gearbeitet wird, ist die Linienextraktion aus Fernerkundungsbildern (TUPIN *et al.* 1998, HELLWICH 1997). Die zu extrahierenden Objekte (v.a. Straßen) zeichnen sich dadurch aus, dass sie aufgrund einer kleinen Umgebung im Bild klassifiziert werden können. Das Zufallsfeld wird dazu verwendet, die entstehenden Liniensegmente zu verknüpfen.

Zufallsfelder haben oft einen sehr kleinen Konvergenzradius in Abhängigkeit vom Lösungsverfahren (s. Abs. 2.2.5). MIGNOTTE *et al.* 1997 (Sonar-Bilder) und KATO *et al.* 1995 verwenden daher eine hierarchische Segmentierung. GÜNSEL *et al.* 1996 hat die Nützlichkeit des hierarchischen Vorgehens für die Linienextraktion gezeigt.

## 1.5 Ziel des Verfahrens

Das hier vorgestellte Verfahren versucht die Erfahrungen der in diesem Abschnitt dargestellten Arbeitsgebiete zu verknüpfen und den gesteigerten Anforderungen der Gebäuderekonstruktion gerecht zu werden. Dazu wird ein Ansatz gewählt,

- der die Verwendung von multisensoriellen Daten ermöglicht,
- der von den ursprünglichen Daten durch die Ableitung einer symbolischen Datenbeschreibung abstrahiert,
- der eine generische Repräsentationsform für Gebäude wählt,
- der die Geometrie der Gebäude durch semantische Information erweitert und dadurch die Interpretation mit der Rekonstruktion verbindet.

Die Möglichkeiten des gewählten Ansatzes werden durch eine Realisierung auf der Basis von Laserscannerdaten aufgezeigt.

Grundsätzlich verfolgt der hier favorisierte Ansatz eine dreistufige Lösung:

1. Detektion
2. näherungsweise Rekonstruktion der Repräsentation
3. Rekonstruktion und Interpretation

In dieser Arbeit wird die Detektion von einzelnen Gebäuden als gelöst angenommen und daher nicht genauer untersucht. Hier kann auf Arbeiten von WEIDNER 1995, HAALA UND BRENNER 1997 oder BRUNN UND WEIDNER 1998 verwiesen werden.

Es wird jedoch nur angenommen, dass die Detektion im Schritt 1 ungefähr die Position eines Gebäudes liefert, weshalb die Rekonstruktion und Interpretation auch Modelle für Nicht-Gebäudeteile vorhalten muß. Es wird z. B. angenommen, dass alle Elemente am Rand Teil des umgebenden Geländes sind.

Nach der Detektion erzeugt der zweite Schritt eine Näherungsrepräsentation für die unterschiedlichen Aspekte der Gebäudes. Eine Lösung wird für die Ableitung eines Simplizialen Komplexes aus einem Digitalen Oberflächenmodell (DOM) beschrieben. Es handelt sich dabei um ein Verfahren zur Generierung einer geometrischen Näherungsoberfläche aus einem Digitalen Höhenmodell.

In einem dritten Schritt wird die Näherungsrepräsentation aufgrund von Modellwissen über Gebäude korrigiert. Hier wird ein Markoff-Zufallsfeld verwandt, dass es ermöglicht, Wechselbeziehungen zwischen Objektteilen lokal zu bewerten. Das Modellwissen wird in bedingten Wahrscheinlichkeiten über Klassifikationen von Knoten, Linien und Flächen in deren Nachbarschaften kodiert.

Die Wiederholung der vorhergegangenen zwei Schritte (Interpretation und Rekonstruktion) für unterschiedliche Gebäudemodelle ermöglicht eine abschließende Klassifikation der Rekonstruktion und liefert damit eine Klassifikation des Types des gesamten Gebäudes.




Abbildung 1.4: Zwei Gebäudegrundtypen: Flachdach- und Walmdachhaus

Die Arbeit beschränkt sich auf die Rekonstruktion, Interpretation und Erkennung einfacher Gebäudetypen (s. Abb. 1.4). Auf eine Erweiterung des Verfahrens auf Gebäudeteile wird im Ausblick eingegangen.

## 1.6 Übersicht über die Arbeit

Die Arbeit gliedert sich in sechs Kapitel. In dem dieser Einleitung folgenden Kapitel werden die Grundlagen der topologischen Repräsentation, der Zufallsfelder und Parameterschätzer gelegt. In Kapitel 3 wird das Konzept der kombinierten Rekonstruktion und Interpretation von Polyederoberflächen beschrieben. Es wird dabei besonderer Wert auf die Repräsentation von Oberflächen und Modellen gelegt. Danach, in Kapitel 4, wird das allgemeine Modell auf die Realisierung der Interpretation und Rekonstruktion einer triangulierten Polyederoberfläche spezialisiert. Als Oberflächenbeobachtungen werden Laserscannerdaten verwandt. Erste Ergebnisse von synthetischen Beispiel und einem realen Datensatz werden im Kapitel 5 gezeigt. Abschließend folgt die Zusammenfassung mit einem Ausblick auf Fragestellungen, die sich aus dieser Arbeit ergeben.



# Kapitel 2

## Theoretische Grundlagen

In diesem Kapitel werden die mathematischen und statistischen Grundlagen für diese Arbeit gelegt. Dabei beschränkt sich die Beschreibung auf wesentliche Aspekte. Weitere Spezialisierungen sind im Anhang der Arbeit zu finden.

Im ersten Abschnitt des Kapitels wird auf die wichtigsten Zusammenhänge des algebraischen topologischen Raumes der Objektrepräsentation eingegangen und es werden die Eigenschaften dieses Raumes festgehalten. Abschnitt 2.2 führt nach der Zusammenfassung relevanter Sätze

der Bayes-Statistik in die Grundlagen der Zufallsfelder ein. Der letzte Abschnitt dieses Kapitels gibt kurz die verwendeten Schätzmodelle ohne mathematischen Beweis wieder.

### 2.1 Topologie triangulierter Polyederoberflächen

#### 2.1.1 Polyederoberflächen

Die verwendete Gebäuderepräsentation basiert auf Polyederoberflächen. Die Eigenschaften von Polyederoberflächen werden in diesem Abschnitt kurz beschrieben. Für eine ausführlichere Erläuterung sei hier auf PREPARATA UND SHAMOS 1985 und EDELSBRUNNER 1987 verwiesen.

Ein  $d$ -Tupel  $\mathbf{x} = (x_1, \dots, x_d)^T$  bestimme einen Punkt  $P$  im  $E^d$ . Gleichzeitig bezeichne das  $d$ -Tupel den Ortsvektor im  $E^d$  zu diesem Punkt  $P$ . Seine Komponenten seien Koordinaten.

Enthalte eine Menge  $\mathcal{P}$  die Punkte  $P_1, P_2, \dots, P_k$  mit den Koordinaten  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_k$ . Die *Linearkombination* von  $\mathcal{P}$  ist mit

$$\lambda_1 \mathbf{x}_1 + \lambda_2 \mathbf{x}_2 + \dots + \lambda_k \mathbf{x}_k \quad \text{mit} \quad \lambda_1, \dots, \lambda_k \in \mathbb{R} \quad (2.1.1)$$

definiert. Die Menge aller Linearkombinationen von einer Punktmenge  $\mathcal{P}$  wird mit  $\mathcal{L}(\mathcal{P})$  bezeichnet. Ein Punkt  $S$  mit den Koordinaten  $\mathbf{s}$  heißt *linear abhängig* von  $\mathcal{P}$  genau dann, wenn  $S \in \mathcal{L}(\mathcal{P})$ . Falls  $S \notin \mathcal{L}(\mathcal{P})$ , so heißt  $S$  *linear unabhängig* von  $\mathcal{P}$ .

Seien  $k$  ausgezeichnete Punkte  $P_1, P_2, \dots, P_k$  mit den Koordinaten  $\mathbf{x}_i, i \in \{1, \dots, k\}$  im  $E^d$  gegeben, dann wird die Menge aller Punkte  $P$  mit den Koordinaten

$$\mathbf{x} = \alpha_1 \mathbf{x}_1 + \alpha_2 \mathbf{x}_2 + \dots + \alpha_k \mathbf{x}_k, \quad (\alpha_j \in \mathbb{R}, \alpha_1 + \alpha_2 + \dots + \alpha_k = 1) \quad (2.1.2)$$

als deren *affine Menge* bezeichnet und  $\mathbf{x}$  ist dann eine *affine Kombination*. Die Punkte werden als *affin unabhängig* bezeichnet, wenn die  $(k - 1)$  Vektoren

$$\mathbf{x}_2 - \mathbf{x}_1, \mathbf{x}_3 - \mathbf{x}_1, \dots, \mathbf{x}_k - \mathbf{x}_1 \quad (2.1.3)$$

linear unabhängig sind. Die  $k$  Punkte sind dann in *allgemeiner Lage*. Eine Linie ist daher die affine Menge zweier affin unabhängiger Punkte. Die affine Menge für drei beliebige Punkte ist eine Ebene. Mit *affiner Hülle*  $\text{aff}(\mathcal{L})$  von  $\mathcal{L}$  wird die kleinste affine Menge aus  $\mathcal{L} \subset E^d$  bezeichnet, die  $\mathcal{L}$  vollständig enthält.

Seien  $k$  ausgezeichnete Punkte  $P_1, P_2, \dots, P_k$  mit den Koordinaten  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_k$  im  $E^d$  gegeben, dann wird die Menge aller Punkte  $P$  mit

$$\mathbf{x} = \alpha_1 \mathbf{x}_1 + \alpha_2 \mathbf{x}_2 + \dots + \alpha_k \mathbf{x}_k, \quad (\alpha_j \in \mathbb{R}, \alpha_j \geq 0, \alpha_1 + \alpha_2 + \dots + \alpha_n = 1) \quad (2.1.4)$$

als deren *konvexe Menge* bezeichnet und jedes  $P$  ist dann eine *konvexe Kombination*. In Erweiterung zur Definition der affinen Menge wird hier noch die Nichtnegativität der Koeffizienten der Kombination gefordert. Analog lässt sich dann die kleinste konvexe Menge, die  $\mathcal{L}$  vollständig enthält, aus  $\mathcal{L}$  mit *konvexer Hülle*  $\text{konv}(\mathcal{L})$  von  $\mathcal{L}$  bezeichnen. Die Dimension einer konvexen Menge ist gleich der Dimension ihrer affinen Hülle. Spezielle konvexe Mengen sind das Liniensegment und das Dreieck.

Ein *Liniensegment*  $E$  (edge) wird durch den Teil einer Linie bestimmt, der zwischen zwei ausgezeichneten Punkten liegt.

Eine Menge ist eine *konvexe Menge*, wenn alle Punkte durch ausschließlich innerhalb der Menge liegende Liniensegmente miteinander verbunden werden können.

Ein *Polygon* ist eine Menge von Punkten, von denen jeder mit genau zwei anderen Punkten verbunden ist. Die Verbindungen sind die Liniensegmente. Ein *konvexes Polygon* ist ein Polygon, in dem alle Endpunkte der Liniensegmente miteinander verbunden werden können, ohne dass der durch das Polygon eingeschlossene Raum verlassen werden muss. Ein konvexes in einer Ebene liegendes Polygon hat aufgrund des Zusammenhangs mit der Dimension der affinen Hülle die Dimension zwei.

Bei Polyederoberflächen sind auf ungerichteten Graphen definiert. Ein ungerichteter Graph besteht aus einer endlichen Menge von Elementen (*Knoten*  $\mathcal{V}$ ) mit einer zugeordneten Menge von ungeordneten Paaren von Elementen (*Kanten*  $\mathcal{E}$ ). Den Kanten sind keine Richtungen hinzugefügt und keine Kante verbindet einen Knoten mit sich selbst (Beschränkung auf *azyklische* Graphen).

Ein *planarer* oder *plättbarer Graph* ist ein Graph  $G(\mathcal{V}, \mathcal{E})$ , der in eine Ebene einbeschrieben werden kann, ohne dass sich zwei Liniensegmente des Graphen schneiden.

Ein *Polyeder (Vielflach)* ist eine endliche Menge von ebenen Polygonen, so dass jede Kante jedes Polygons mit exakt einem anderen Polygon geteilt wird, und keine Teilmenge der Polygone hat die gleiche Eigenschaft. Es handelt es sich also bei einem Polyeder um eine geschlossene Fläche, die sich aus Vielecken zusammensetzt (MÜLLER UND WÖLPERT 1976). Die Knoten, Kanten und Flächen bilden lokal stets einen plättbaren Graphen auf der Kugel. Die Plättbarkeit Maß nicht für den gesamten Polyeder gelten. Eine *Polyederoberfläche* ist ein an mindestens einer Polygonseite offenes Polyeder.

Eine Unterteilung der Ebene ist eine *Triangulation*, wenn alle Regionen durch Polygone mit drei Punkten (Dreiecke) umschrieben sind.

Die Menge  $\mathcal{P}$  der Punkte der Triangulation wird im Folgenden als Knotenmenge, die Menge der Liniensegmente als Kantenmenge  $\mathcal{E}$  und die Menge der daraus resultierenden Flächen als Menge  $\mathcal{F}$  bezeichnet<sup>1</sup>.

Eine *triangulierte Oberfläche* ist eine Polyederoberfläche mit einer maximalen Anzahl von Kanten. Die Flächen bilden Dreiecke. Wird eine triangulierte Polyederoberfläche einer Ebene einbeschrieben, ergibt sich eine Triangulation.

Die Anzahl der abgehenden Kanten von einem Knoten  $V$  wird als Kardinalität  $\text{card}(V)$  bezeichnet. Ein Knoten  $V$ , der nicht vollständig von Dreiecken umgeben ist, wird als *Randknoten* bezeichnet. Eine Kante  $E$ , deren beide Anfangs- und Endknoten Randknoten sind, wird als *Randkante* bezeichnet.

Zur Repräsentation von Triangulationen wird eine doppelt verkettete Kantenliste verwendet (PREPARATA UND SHAMOS 1985, S. 17). Dazu werden alle Kanten der Triangulation abgelegt. Als Attribute erhalten die Kanten ihren Anfangs- und Endpunkt, das linke und das rechte Dreieck, sowie die Kennungen einer ihrer vorhergehenden und einer ihrer nachfolgenden Kante. Eine vorhergehende Kante ist die nächste Kante gegen den Uhrzeigersinn im Anfangspunkt. Eine nachfolgende Kante ist die nächste Kante gegen den Uhrzeigersinn im Endpunkt. Eine Kante ist in Abb.

<sup>1</sup>Um die Äquivalenz der Triangulation mit einem ungerichteten Graphen zu zeigen, wird für die Knoten und Kanten hier die gleiche Bezeichnung gewählt.

2.1 dargestellt. Durch den Orientierungssinn einer Kanten in den Knoten ist eine Orientierung der Fläche definiert. Die Orientierung der Fläche (s. DOCARMO 1993) verhindert die Repräsentation




Abbildung 2.1: Datenstruktur für Kanten einer triangulierten Oberfläche: Die Dreiecksstruktur ist gepunktet dargestellt, die Kante mit den zugeordneten vorhergehenden und nachfolgenden Kanten ist hervorgehoben. Der Innenwinkel entscheidet über die explizit abgespeicherte Information.

nicht orientierbarer Flächen, also Flächen, die ein nicht stetig interpolierbares Einheitsnormalenvektorfeld besitzen (z. B. Möbiusbänder)<sup>2</sup>.

Nachbarschaften von Flächen auf Polyederflächen lassen sich explizit durch den dualen Graphen darstellen (s. a. MÜLLER UND WÖLPERT 1976).

**Definition 2.1.1 (Dualer Graph)** *Der duale Graph eines plättbaren Graphen entsteht durch folgende Vorschriften:*

1. *Jeder Fläche des Graphen wird ein Knoten in einem neuen Graphen zugeordnet.*
2. *Für jede Kante des alten Graphen wird eine Kante im neuen Graphen erzeugt, die die beiden neuen Knoten verbindet, deren entsprechenden Flächen im alten Graphen zu der Kante benachbart sind.*

## 2.1.2 Topologische Komplexe

Im Folgenden sollen auf der triangulierten Polyederoberfläche Nachbarschaften definiert werden. Die Nachbarschaften werden durch Simplizes festgelegt (JÄNICH 1994, S. 109, DOLD 1972):

**Definition 2.1.2** *Unter einem  $k$ -dimensionalen Simplex oder  $k$ -Simplex im  $E^d$  verstehen wir die konvexe Hülle  $s(p_0, \dots, p_k)$  von  $k + 1$  Punkten in allgemeiner Lage.*

Ein Simplex enthält alle seine Teilsimplizes (Seiten). Die Nachbarschaftsrelationen eines  $k$ -Simplizes sind durch die Teilsimplizes der Ordnung  $(k - 1)$  definiert. Da die Nachbarschaftsrelation symmetrisch ist, ist auch der  $(k - 1)$ -Simplex Nachbar des  $k$ -Simplex, sofern er vorhanden ist. Die *Nachbarschaft oder der Rand eines Simplex  $s$*  wird mit  $\partial s$  bezeichnet.

Die 0-Simplizes werden als Punkte, die 1-Simplizes als Kanten und die 2-Simplizes werden als Dreiecke bezeichnet.

<sup>2</sup>Für den Interpretations- und Rekonstruktionsprozess reicht die lokale Orientierbarkeit eigentlich aus. Da natürliche Gebäude in der Regel orientierbare Oberflächen haben, bedeutet die Beschränkung der Repräsentation der Triangulation keine Einschränkung für die Anwendbarkeit des Verfahrens.

Auf der Basis der Simplexdefinition folgt die Definition eines simplizialen Komplexes oder Polyeders (analog zu JÄNICH 1994, S. 110):

**Definition 2.1.3** Eine endliche Menge  $K$  von Simplizes im  $\mathbb{R}^n$  heißt simplizialer Komplex oder ein Polyeder, wenn folgende zwei Bedingungen erfüllt sind:

- Mit jedem seiner Simplizes enthält  $K$  auch dessen sämtliche Teilsimplizes.
- Der Durchschnitt von je zwei Simplizes von  $K$  ist entweder leer oder ein gemeinsamer Teilsimplex.

Eine allgemeine Form der Objekttopologie bilden die CW-Komplexe. Notwendig zur Definition der CW-Komplexe ist der Hausdorffraum.

**Definition 2.1.4** Ein topologischer Raum heißt Hausdorffraum, wenn man zu je zwei verschiedenen Punkten disjunkte Umgebungen finden kann.

Damit ist die Definition der CW-Komplexe möglich (JÄNICH 1994, S. 118):

**Definition 2.1.5** “Ein Paar  $(X, \mathcal{E})$ , bestehend aus einem Hausdorffraum  $X$  und einer Zellenzerlegung  $\mathcal{E}$  von  $X$  heißt CW-Komplex, wenn folgende drei Axiome erfüllt sind:

*Axiom 1* Zu jeder  $n$ -Zelle  $e \in \mathcal{E}$  gibt es eine stetige Abbildung  $\Phi_e : D^n \rightarrow X$ , welche [die offene Vollkugel]  $\overset{\circ}{D}^n$  homöomorph auf die Zelle  $e$  und den Rand  $S^{n-1}$  in die Vereinigung der höchstens  $(n - 1)$ -dimensionalen Zellen abbildet<sup>3</sup>.

*Axiom 2* Die abgeschlossene Hülle  $\bar{e}$  jeder Zelle  $e \in \mathcal{E}$  trifft nur endlich viele andere Zellen.

*Axiom 3*  $A \subset X$  ist genau dann abgeschlossen, wenn jedes  $A \cap \bar{e}$  abgeschlossen ist.”

Die Bezeichnung “CW-Komplex” bezieht sich auf das zweite und dritte Axiom: das “C” steht für hüllenendlich (engl. *closed-finite*) und das “W” steht für die schwache Topologie (engl. *weak topology*). Für endliche Komplexe sind beide Axiome in trivialer Weise immer erfüllt (JÄNICH 1994, S. 118).

CW-Komplexe erlauben die Definition einer größeren Menge von Objekten als es mit Simplizialen Komplexen möglich wäre. Näheres kann bei JÄNICH 1994, S. 119ff gefunden werden. Ein einfaches Beispiel für einen CW-Komplex ist in Abbildung 2.2 gezeigt. Die CW-Komplexe werden




Abbildung 2.2: Die Topologie einer Würfeloberfläche kann in acht 0-Zellen (Würfecken), zwölf 1-Zellen (Würfelkanten) und sechs 2-Zellen (Würfelflächen) zerlegt werden (JÄNICH 1994, S. 117).

in dieser Arbeit zur Beschreibung des allgemeinen Interpretationsmodells in Kapitel 3 verwandt. Die Simplizialen Komplexe als Spezialisierung der CW-Komplexe auf Triangulationen sind die Grundlage der Repräsentation in Kapitel 4.

<sup>3</sup>  $D^n$  ist die Vollkugel.



## 2.2 Zufallsfelder

### 2.2.1 Das Bayes–Theorem

Es sei  $\mathbf{y}$  ein Zufallsvektor mit den Elementen  $y_i, i \in \{1, \dots, m\}$ , der Beobachtungen oder allgemeiner das Ergebnis eines Beobachtungsprozesses enthält. Mit dem Vektor  $\boldsymbol{\beta}$  mit den Elementen  $\beta_j, j \in \{1, \dots, n\}$  sei ein Vektor unbekannter fester Parameter bezeichnet.  $p(\cdot)$  bezeichne die Verteilungsfunktionen (KOCH 1997, S. 92). Nach dem *Bayes–Theorem* gilt, dass unter Kenntnis der bedingten Verteilung  $p(\mathbf{y}|\boldsymbol{\beta})$  und der Verteilung  $p(\boldsymbol{\beta})$  die Verteilung  $p(\boldsymbol{\beta}|\mathbf{y})$  der unbekannt Parameter unter der Kenntnis der Beobachtungen bis auf eine Proportionalität  $1/Z$  bestimmt werden kann.

$$p(\boldsymbol{\beta}|\mathbf{y}) = \frac{1}{Z} p(\mathbf{y}|\boldsymbol{\beta}) p(\boldsymbol{\beta}) \quad (2.2.1)$$

$$\propto p(\mathbf{y}|\boldsymbol{\beta}) p(\boldsymbol{\beta}) \quad (2.2.2)$$

Die Verteilung  $p(\mathbf{y}|\boldsymbol{\beta})$  wird als Likelihood–Funktion, die Verteilung  $p(\boldsymbol{\beta})$  als Priori–Verteilung und die Verteilung  $p(\boldsymbol{\beta}|\mathbf{y})$  als Posteriori–Verteilung bezeichnet. Der Proportionalitätsfaktor kann über die Integration der rechten Seite über den Parameterraum  $\Theta$  der unbekannt Parameter  $\boldsymbol{\beta}$  bestimmt werden, da die resultierende Verteilung die beiden Axiome für Wahrscheinlichkeiten

$$p(\boldsymbol{\beta}|\mathbf{y}) \geq 0 \quad \text{und} \quad \int_{\Theta} p(\boldsymbol{\beta}|\mathbf{y}) d\boldsymbol{\beta} = 1 \quad (2.2.3)$$

erfüllen muss.

Im Falle einer kontinuierlichen Belegung des Parametervektors ist die Proportionalitätskonstante oftmals nur unter Verwendung von Monte–Carlo–Techniken bestimmbar (KOCH 1990, S. 52, KOCH 2000, S. 183). Enthält der Parameterraum der unbekannt Parameter nur diskrete Belegungen für  $\boldsymbol{\beta}$  reduziert sich das Integral über alle möglichen Belegungen auf eine Summe.

Für diskrete Zufallsvariablen kann die Ableitung des Bayes–Theorems aus der Definition der bedingten Wahrscheinlichkeit

$$p(\boldsymbol{\beta}|\mathbf{y}) = \frac{p(\mathbf{y}|\boldsymbol{\beta}) p(\boldsymbol{\beta})}{p(\mathbf{y})} \quad (2.2.4)$$

erfolgen. Die Proportionalitätskonstante ist dann  $1/p(\mathbf{y})$ .

Das Bayes–Theorem zeigt, wie Vorwissen über die Priori–Verteilung der unbekannt Parameter und die Likelihood–Funktion, über die Beobachtungen hinaus in eine statistische Auswertung integriert werden kann. Ebenso lässt sich Vorwissen durch die Erweiterung des Bedingungsteils der Verteilungen integrieren. Dazu soll nun die Verteilung  $p(\boldsymbol{\beta}|\mathbf{y}, \boldsymbol{\gamma})$  bestimmt werden. Nach dem Bayes–Theorem ergibt sich

$$p(\boldsymbol{\beta}|\mathbf{y}, \boldsymbol{\gamma}) \propto p(\mathbf{y}|\boldsymbol{\beta}, \boldsymbol{\gamma}) p(\boldsymbol{\beta}|\boldsymbol{\gamma}) \quad (2.2.5)$$

Die Likelihood–Funktion enthält nun eine Abhängigkeit zu den Vorinformationen  $\boldsymbol{\gamma}$  und zu den unbekannt Parametern  $\boldsymbol{\beta}$ . Die Priori–Verteilung wird in Abhängigkeit des Vorwissens formuliert. Das Bayes–Theorem in der Form Gl. 2.2.5 lässt sich auch direkt mit dem Vorwissen formulieren (s. KOCH 2000, S. 32).

### 2.2.2 Formulierung des Zufallsfeldes

Zeitabhängige Prozesse, die neben einem deterministischen Verhalten auch einem zufälligen Einfluss unterliegen, werden als *Zufallsprozesse* bezeichnet. Das Verhalten des Prozesses wird in einer Zufallsvariablen über die Zeit beobachtet. Man schreibt

$$X(t, s) \quad \text{oder kürzer} \quad X(t). \quad (2.2.6)$$

Der Parameter  $t$  mit  $(t \in \{t_0, \dots, t_m\})$  markiert endlich viele Zeitpunkte<sup>4</sup>.  $s$  ist ein Element der Menge der Elementarereignisse. Eine Belegung der Zufallsvariablen  $X$  zu einem Zeitpunkt  $t$ , wenn  $s$  also ein bestimmtes Elementarereignis annimmt, heißt *Realisierung*. Die Zeit gibt die Entwicklungsrichtung des stochastischen Prozesses an. Die Verteilungsfunktion des Zufallsprozesses lässt sich als

$$F(t_0, t_1, \dots, t_n) = P(X(t_0) < x_0, \dots, X(t_n) < x_n) \quad (2.2.7)$$

angeben. Falls die Verteilungsfunktion differenzierbar ist, führt das auf die Dichte

$$p(x_0, \dots, x_n). \quad (2.2.8)$$

Für diskrete Zufallsvariablen wird diese Dichte als Wahrscheinlichkeit  $P(x_0, \dots, x_n)$  geschrieben.

Um nicht die Verteilungsfunktion  $P(x_0, \dots, x_n)$  vollständig angeben zu müssen, kann als Vereinfachung der Verteilungsfunktion für bestimmte Prozesse die Markoff-Eigenschaft eingeführt werden. Das führt auf den Markoff-Prozess.

**Definition 2.1 (Markoff-Prozess)** (KOCH UND SCHMIDT 1994, S. 180) *Einen stochastischen Prozess  $X(t)$  bezeichnet man als Markoff-Prozess, falls für die Wahrscheinlichkeiten  $x(t_n) < x_n$  für beliebiges  $x_n$  unter der Bedingung, dass die Zufallsvariablen  $X(t_0)$  bis  $X(t_{n-1})$  zu den vorangegangenen Zeiten die Werte von  $x_0$  bis  $x_{n-1}$  angenommen haben, gilt*

$$\begin{aligned} P(X(t_n) < x_n | X(t_0) = x_0, X(t_1) = x_1, \dots, X(t_{n-1})) \\ = P(X(t_n) < x_n | X(t_{n-1}) = x_{n-1}) \end{aligned} \quad (2.2.9)$$

Die Entwicklung des stochastischen Prozesses hängt zum Zeitpunkt  $t_n$  also nur von der Realisierung zum Zeitpunkt  $t_{n-1}$  ab. Die Gültigkeit der Markoff-Eigenschaft auch in umgekehrter Richtung ergibt sich mit dem Bayes-Theorem (KOCH UND SCHMIDT 1994, S. 181). Gilt

$$p(x_n | x_{n+1}, \dots, x_{n+p}) = p(x_n | x_{n+1}), \quad (2.2.10)$$

so gilt auch

$$p(x_n | x_{n-1}, \dots, x_{n-q}) = p(x_n | x_{n-1}). \quad (2.2.11)$$

$p$  und  $q$  sind beliebig ( $p, q > 1$ ). Die Markoff-Eigenschaft ist ebenfalls symmetrisch

$$p(x_n | x_0, x_a, \dots, x_{n-1}, x_{n+1}, x_{n+2}, \dots, x_m) = p(x_n | x_{n-1}, x_{n+1}). \quad (2.2.12)$$

Aufgrund dieser Eigenschaft können im folgenden die Markoff-Prozesse auf Zufallsfeldern verallgemeinert werden. Ein Markoff-Prozess mit einer diskreten Indexmenge und einer abzählbaren Menge von Elementarereignissen ist eine *Markoff-Kette* (KOCH UND SCHMIDT 1994, S. 182).

### 2.2.3 Markoff-Zufallsfelder

Im Falle von Zufallsprozessen markiert die Zeit  $t$  die Entwicklungsrichtung des Prozesses. Um auf  $n$ -dimensionale Zufallsprozesse zu verallgemeinern, wird von der Zeit abstrahiert und ein  $n$ -dimensionaler Vektor  $\mathbf{t}$  eingeführt. Die Menge  $\mathcal{T}$  aller Indexvektoren  $\mathbf{t}$  sei beschränkt und abzählbar. Dann können die Indexvektoren mit einem Zähler  $g$  nummeriert werden.

**Definition 2.2 (Zufallsprozess)** *Eine Folge von Zufallszahlen*

$$X(\mathbf{t}(g), s) = X(g, s)$$

*bezeichnet man als  $n$ -dimensionalen Zufallsprozeß oder als ein-dimensionales Zufallsfeld. Abgekürzt lässt sich wiederum*

$$X(\mathbf{t})$$

*schreiben.*

---

<sup>4</sup>Zufallsprozess mit einer überabzählbaren Anzahl von Indizes werden nicht betrachtet.

Die Verteilungsfunktion des Zufallsfeldes lässt sich mit den Indizes  $g \in \{g_0, \dots, g_n\}$  als

$$F(g_1, \dots, g_n) = P(X(g_0) < x_0, \dots, X(g_n) < x_n)$$

angeben. Die *lokale Charakteristik* beschreibt, wie die Verteilung einer Zufallsvariablen  $X(g)$  von den anderen Zufallsvariablen abhängt und kann als bedingte Wahrscheinlichkeitsverteilung formuliert werden:

$$P(X(g_i) < x_i | X(g_j) = x_j \quad \text{für alle} \quad g_j \in \mathcal{T} \setminus \{g_i\})$$

Um die lokale Charakteristik der Markoff-Eigenschaft einzuführen, wird ein ungerichteter Graph definiert, dessen Knoten die Zufallsvariablen des Zufallsfeldes sind. Jeder Knoten  $v$  des Graphen wird also auf eine Zufallsvariable  $s$  abgebildet.

$$\mathcal{V} \rightarrow \mathcal{S} \tag{2.2.13}$$

$$v \mapsto s \tag{2.2.14}$$

Die Kanten des Graphen definieren Graphnachbarschaften<sup>5</sup>.

Eine besondere lokale Charakteristik haben Markoff-Zufallsfelder (MRF)<sup>6</sup>.

**Definition 2.3 (Markoff-Zufallsfeld)** (KOCH UND SCHMIDT 1994, S. 256)

$$\begin{aligned} P(X(g_i) < x_i \mid X(g_j) = x_j \quad \text{für alle} \quad g_j \in \mathcal{T} \setminus \{g_i\}) \\ = P(X(g_i) < x_i | X(g_j) = x_j \quad \text{für alle} \quad g_j \in \partial\{g_i\}) \end{aligned}$$

$\partial\{g_i\}$  meint die Menge der Knoten in der Nachbarschaft des Knotens  $g_i$ . Die Indexmenge sei abzählbar. Die Bestimmung der Gesamtwahrscheinlichkeiten des Markoff-Zufallsfeldes aufgrund der Wahrscheinlichkeiten der Knoten ist allgemein nicht möglich, da die Wahrscheinlichkeiten nicht unabhängig bestimmt werden<sup>7</sup>. Zur Ableitung der Berechnungsvorschrift für die Wahrscheinlichkeitsverteilung des gesamten Zufallsfeldes führen wir nun Gibbsfelder ein.

Die Gibbsfelder sind aus der Physik bekannt. Das Gesamtpotential eines Gibbsfeldes setzt sich als Summe aller Teilpotentiale  $U_A$  seiner Zustandvektoren  $\mathbf{x}$  zusammen.

$$U(\mathbf{x}) = \sum_A U_A(\mathbf{x}) \tag{2.2.15}$$

Die Verteilung des Feldes ist definiert als

$$p(\mathbf{x}) = \frac{1}{Z} \exp(-U(\mathbf{x})) \tag{2.2.16}$$

Als eine andere Form der Gibbs-Verteilung findet man auch

$$p(\mathbf{x}) = \frac{1}{Z} \exp(-U(\mathbf{x})/T_o),$$

wobei  $T_o$  die Variabilität des Feldes steuert.

Teilpotentiale werden auf Teilmengen von Elementen des Feldes definiert. Teilmengen, die Nachbarschaften enthalten, werden als Cliques bezeichnet<sup>8</sup>. Die Nachbarschaft von  $\mathbf{x}$  wird mit  $\partial\mathbf{x}$  bezeichnet.

<sup>5</sup>KINDERMANN UND SNELL 1994, S. verwenden auch Graphen und definieren aber zwei Knoten entsprechend der Graphentheorie als benachbart, wenn sie durch eine Kante miteinander verbunden sind. Wir verwenden eine allgemeinere Definition der Nachbarschaft.

<sup>6</sup>engl. *Markov Random Field*

<sup>7</sup>Die zur Beschreibung des Markoff-Zufallsfeldes notwendigen bedingten Wahrscheinlichkeiten lassen sich in der Regel schwierig angeben. Üblicherweise werden zur Umgehung der bedingten Wahrscheinlichkeiten Gibbsfelder eingeführt, die auf Potentialen definiert werden. In dieser Arbeit werden die bedingten Wahrscheinlichkeiten jedoch automatisch gelernt (s. Abs. 3.1.4). Daher wäre aus diesem Grund hier die Definition der Gibbsfelder nicht notwendig.

<sup>8</sup>Als Cliques ergeben sich bei KINDERMANN UND SNELL 1994, S. 26 Einer-, Zweier- und Dreiercliques, die z. B. auf einer Triangulation zu dem Knoten selbst, einer Kante und einem Dreieck werden. Größere Cliques sind aufgrund der Cliquendefinition und der Festlegung der Nachbarschaft sind hier nicht möglich (s. KINDERMANN UND SNELL 1994, S. 26).

**Definition 2.4 (Clique)** Eine Teilmenge  $C \subset T$  von Knoten der Indexmenge ist eine Clique, falls

1.  $C = t_i$  oder
2.  $t_j \in \partial t_i$  für alle  $t_i, t_j \in C$  und  $i \neq j$ ,

wenn  $t_i = t(g_i)$  gesetzt wird.

Die Potentiale entsprechen dem Begriff der *Information* in der Informationstheorie und Statistik.

Ein Gibbsfeld, dessen Verteilung nicht von allen Cliquen abhängt, wird als Nachbarschafts-Gibbsfeld bezeichnet. Wenn  $K$  die Menge aller Cliquen in  $T$  ist, bezeichnet man das Gibbsfeld als *Nachbarschafts-Gibbsfeld*, wenn

$$U_Z(\mathbf{s}) = 0 \quad \text{für} \quad Z \notin K \quad (2.2.17)$$

gilt. Ein Zufallsfeld, das eine Gibbs-Verteilung besitzt wird als Gibbs-Zufallsfeld bezeichnet.

Hammersley und Clifford haben auf die Äquivalenz von Markoff-Zufallsfeldern und Nachbarschaftsgibbsfeldern hingewiesen.

**Theorem 2.2.1** Ein diskretes Zufallsfeld  $X(g_i)$  mit  $i \in \{0, 1, \dots, n\}$  ist genau dann ein Markoff-Zufallsfeld, wenn seine Dichte  $p(\mathbf{s})$  durch die Gibbs-Verteilung des Nachbarschaft-Gibbsfeldes gegeben ist.

Der Beweis ist z. B. in KOCH UND SCHMIDT 1994, S. 261 zu finden. Aufgrund der Äquivalenz der Nachbarschaft-Gibbsfelder mit den Markoff-Zufallsfeldern werden im Folgenden die Knoten wieder mit  $s$  bezeichnet.

Die Definition eines Markoff-Zufallsfeldes (MRF) kann aufgrund der Äquivalenz zu den Gibbsfeldern auch in der folgenden Weise formuliert werden (LI 1995, S. 11): Sei  $\mathcal{S}, s \in \{1 \dots n_s\}$  eine Menge von Knoten eines MRFs und  $\mathcal{L}, l \in \{1 \dots n_l\}$  eine Menge von möglichen Klassifikationen eines jeden Knotens. Eine Belegung der Knotenmenge wird mit  $s_i$  bezeichnet. Es soll die wahrscheinlichste Knotenbelegung für die Gesamtheit aller Knoten gefunden werden. Dabei soll gelten, dass

- $P(\mathbf{s}) > 0$  (Positivität) und
- $P(s|\mathcal{S}) = P(s|\partial s)$  (Markov-Eigenschaft oder Markovinität).

Die Positivität folgt direkt aus der Äquivalenz zu den Gibbsfeldern, da reelle Potentiale immer zu einer Wahrscheinlichkeit größer Null führen.

Die Äquivalenz von Markoff-Zufallsfeldern und Nachbarschaftsgibbsfeldern ermöglicht dem Benutzer die Art der Modellierung frei zu wählen. Die gemeinsame Verwendung von Potentialen und bedingten Wahrscheinlichkeiten wird somit möglich.

Die Äquivalenz ermöglicht auch die Berechnung der Gesamtwahrscheinlichkeit des Markoff-Zufallsfeldes. Für die Berechnung darf jedoch jedes Cliquenpotential nur einmal verwandt werden.

$$P(\mathbf{s}) = \exp \sum U_A = \exp \sum -\ln(P_A(\mathbf{s})) \quad \text{für} \quad A \in K \quad (2.2.18)$$

Wenn zur Berechnung der lokalen Klassifikationswahrscheinlichkeiten keine Cliquen doppelt verwandt werden, lässt sich die Gesamtwahrscheinlichkeit des Zufallsfeldes mit

$$p(\mathbf{s}) = \prod_i p(s_i) \quad (2.2.19)$$

angeben. Diese Eigenschaft wird später zur Bestimmung der Gesamtwahrscheinlichkeit der Zufallsfelder genutzt.

### 2.2.4 Verkoppelte Markoff-Zufallsfelder

Verkoppelte Markoff-Zufallsfelder (CMRF<sup>9</sup>) sind eine konzeptionelle Erweiterung des MRFs. Sie wurden bisher im wesentlichen für die Bildsegmentierung bei gleichzeitiger Modellierung von Regionenpixeln und Kanten verwendet (z. B. LI 1995, S. 12). Die verkoppelten Markoff-Zufallsfelder sollen nun hier formal definiert werden: Seien  $n_s$  MRFs  $\mathcal{S}^i, s^i \in \{1 \dots n_{s^i}\}, i \in \{1 \dots n_s\}$  gegeben, die untereinander verkoppelt sind, d.h. jedes MRF hat Abhängigkeiten zu mindestens einem anderen Zufallsfeld

$$P(s^i | s^j) \neq P(s^i) \quad \text{für mindestens ein} \quad s^j \in \partial s^i. \quad (2.2.20)$$

Die Menge aller Knoten des MRFs sei mit  $\mathcal{S}$  bezeichnet.

$$\mathcal{S} = \bigcup_{i \in \{1 \dots n_s\}} \mathcal{S}_i \quad (2.2.21)$$

Für jedes MRF sei eine Nachbarschaft

$$\partial s^i \subset \mathcal{S} \quad (2.2.22)$$

definiert.

Verkoppelte MRFs wurden bisher eingesetzt, um die glättende Eigenschaft des MRF zu umgehen, da nicht verkoppelte MRFs durch die Eigenschaften der Homogenität und Isotropie und durch die Nachbarschaftsdefinition glättend auf den Wahrscheinlichkeitsverteilungen wirken. Abstrakt betrachtet, können Verkoppelungen als lokale Einflüsse auf das Standardverhalten eines MRFs formuliert werden, so dass durch eine Verkoppelung auch eine Verstärkung von Strukturen möglich ist.

### 2.2.5 Lösungsverfahren

Die optimale Realisierung der MRFs wird im Allgemeinen iterativ gesucht, dabei werden sequentiell oder parallel lokale Konfigurationen in jedem Iterationsschritt bewertet. Deshalb wird der lokale und der globale Lösungsansatz unterschieden (LI 1995). Im nächsten Abschnitt werden die lokalen Lösungsverfahren beschrieben, im darauf folgenden Abschnitt wird auf die globalen Lösungsstrategien eingegangen.

#### 2.2.5.1 Lokale Lösungsverfahren

Für die lokale Bewertung von Wahrscheinlichkeitsfunktionen werden zwei Bewertungsfunktionen verwandt:

- die Erwartungswertschätzung und
- die *Maximum-A-Posteriori*-Schätzung (MAP-Schätzung)

Die Erwartungswertschätzung wird im Allgemeinen für kontinuierliche oder numerisch sortierte, diskrete Zufallsvariablen  $s$  verwandt. Als Schätzung wird der Erwartungswert

$$E(s) = \int s p(s) ds \quad \text{oder} \quad E(s) = \sum_k s_k p(s_k) \quad (2.2.23)$$

bestimmt. Die MAP-Schätzung bestimmt die Belegung der Zufallsvariable, der die maximale Wahrscheinlichkeit oder die maximale Verteilungsdichte zugeordnet ist.

$$\hat{s} = \arg \max_s p(s) \quad \text{oder} \quad \hat{s} = \arg \max_{s_k} p(s_k) \quad (2.2.24)$$

In dieser Arbeit wird für die Klassifikation im MRF ausschließlich die MAP-Schätzung verwandt (s. KOCH 2000, S. 70), da es sich um nicht sortierte diskrete mögliche Belegungen der Zufallsvariablen handelt.

<sup>9</sup> engl. *Coupled Markov Random Field*

### 2.2.5.2 Globale Lösungsverfahren

Als Lösung der MRFs wird eine Belegung der Zufallsvariablen gesucht, die optimal in Bezug auf das Vorwissen und die Beobachtungen ist.

Markoff-Zufallsfelder können im Allgemeinen nicht durch direkte Lösungsverfahren gelöst werden. Die große Anzahl der zu bestimmenden Zufallsparameter und die Nichtlinearität des Problems stehen dem entgegen. Schwierig bei der Suche nach der optimalen Lösung des MRFs sind insbesondere nicht-konvexe Gesamtwahrscheinlichkeitsfunktionen des Netzes. Es werden iterative Verfahren verwandt, die sich daher in die deterministischen und die stochastischen Lösungsverfahren aufteilen.

Innerhalb beider Gruppen von Lösungsverfahren werden lokale Nachbarschaften bewertet und so die Schätzung lokal optimiert. Dabei lassen die deterministischen Verfahren nur Veränderungen der Schätzgrößen zu, die eine höhere Wahrscheinlichkeit erreichen. Die stochastischen Verfahren erlauben mit einer vorgegebenen Wahrscheinlichkeit auch eine Verschlechterung der lokalen Schätzung gegenüber der vorhergehenden Iteration.

In dieser Arbeit werden exemplarisch zwei Standardverfahren zur Lösung des MRFs verwendet. Diese beiden sind im folgenden kurz beschrieben.

Eines der deterministischen Verfahren ist der ICM-Algorithmus *Iterated Conditional Modes*.

**ICM-Algorithmus** Iterated Conditional Modes (BESAG 1986, KOCH UND SCHMIDT 1994, S. 323, LI 1995, S. 189)

1. Näherungslösung aus lokaler Klassifikation der Knoten bestimmen.
2. Zufälliges Aufsuchen aller Knoten in jedem Iterationsschritt
  - (a) Lokal beste Belegung des Knotens unter Berücksichtigung der Nachbarklassifikationen schätzen.
  - (b) Schätzwert als neue Bezeichnung des Primitives zuweisen
3. Ist das Abbruchkriterium erfüllt, dann Ende sonst weiter bei 2.

Bei der Verwendung von deterministischen Verfahren zur Lösung des Zufallsfeldes ist eine gute Näherungslösung erforderlich, wenn die Bewertungsfunktion (Wahrscheinlichkeitsverteilung des Feldes) nicht konvex ist, da so Hoffnung besteht, bereits an einer Stelle der Bewertungsfunktion zu sein, von der das globale Maximum erreicht werden kann.

Durch das zufällige Aufsuchen aller Knoten in jedem Iterationsschritt werden Knoten an denen in den vergangenen Iterationen keine Veränderungen stattgefunden haben und auch in ihrer Umgebung keine Veränderungen durchgeführt wurden, jedesmal unnütz klassifiziert. Dieses wird durch den HCF-Algorithmus *Highest-Confidence-First* vermieden, der anhand eines Vertrauensmaßes jeweils die Zufallsvariable bewertet, an der die größte Wahrscheinlichkeitssteigerung des MRFs erreicht werden kann. Gleichzeitig bedeutet das aber eine Einschränkung der Vielfalt der Wahrscheinlichkeitsfunktionen, von denen das globale Maximum gefunden werden kann. Dieses Verfahren ist vollständig deterministisch, da selbst die Reihenfolge des Zugriffs auf die Knoten durch die Anfangskonfiguration bestimmt ist.

Als Beispiel für stochastische Lösungsverfahren des Zufallsfeldes wird eine Variante des Metropolis-Algorithmusses verwandt. Hier soll zunächst der Standardalgorithmus beschrieben werden.

**Metropolis–Algorithmus** (METROPOLIS *et al.* 1953, KOCH UND SCHMIDT 1994, S. 324, LI 1995, S. 209)

1. Zufällige Näherungslösung generieren.
2. Auswahl einer Anfangstemperatur  $T$ 
  - (a) Zufälliges Aufsuchen aller Knoten
    - i. Berechnung der Wahrscheinlichkeiten für alle möglichen Klassifikationen.
    - ii. Eine zufällige Lösung  $f'$  für den Knoten wird generiert.
    - iii. Falls  $\text{rand}(0,1) < \min(1.0, \frac{p(f')}{p(f)})$  wird die zufällig gewonnene Klassifikation übernommen.
  - (b) Absenkung der Temperatur nach der gewählten Funktion
  - (c) Abbruch bei stabilem Verlauf der Energiefunktion, sonst wird bei Punkt 2a fortgefahren.

Der Metropolis–Algorithmus wie alle stochastischen Verfahren hat einen wesentlich höheren Rechenaufwand, da mehr Realisierungen des Zufallfeldes bewertet werden. Eine bedeutende Rolle für die Anzahl der betrachteten Alternativlösungen spielt die Temperatur. Eine hohe Temperatur führt zu einer hohen Akzeptanzrate von schlechteren Lösungen, eine Temperatur von 0, überführt das stochastische Verfahren in ein deterministisches.

Probleme ergeben sich bei der Realisierung von Zufallfeldern für die Wahl der Anfangstemperatur und der Abkühlungsfunktion.

### 2.2.6 Beurteilung der Klassifikationsergebnisse

Das Klassifikationsergebnis eines Zufallfeldes, als Ergebnis der Optimierung aus Abs. 2.2.5.2, kann auf unterschiedliche Weise beurteilt werden:

- Als externes Beurteilungskriterium wird der Vergleich mit einer idealen Klassifikation gewählt. Die relative Häufigkeit von Fehlklassifikationen dient zur Beurteilung des Klassifikationsergebnisses. Alle weiteren Kriterien sind innere Maße.
- Die Gesamtwahrscheinlichkeit des Netzes wird bestimmt, indem die einzelnen Klassifikationswahrscheinlichkeiten multipliziert werden (s. Gl. 2.2.19). Dabei wird der absolute Wert der Gesamtwahrscheinlichkeit zur Bewertung der Klassifikationsergebnisse herangezogen.

Um die Güte einer abgeleiteten Klassifikation zu bestimmen, kann zur lokalen Beurteilung das Verhältnis zwischen der besten und der zweitbesten Klassifikation eines Knoten als Klassifikationssicherheit angegeben werden (SZELISKI 1989, S. 56). Dazu werden die posteriori Chancen herangezogen:  $\mathbf{s}_1$  und  $\mathbf{s}_2$  seien zwei mögliche Klassifikationen unter der Bedingung von Daten  $\mathbf{d}$ . Die beiden Realisierung können gegeneinander getestet werden. Es sei  $H_o$  die Hypothese und  $H_1$  die Gegenhypothese.

$$H_o : \mathbf{s} = \mathbf{s}_1 \quad H_1 : \mathbf{s} = \mathbf{s}_2 \quad (2.2.25)$$

Dann ergibt die posteriori Chance

$$o(\mathbf{s}_1, \mathbf{s}_2 | \mathbf{d}) = \frac{p(\mathbf{s}_1 | \mathbf{d})}{p(\mathbf{s}_2 | \mathbf{d})}. \quad (2.2.26)$$

Ebenso ist es möglich, das Klassifikationsergebnis eines Knotens über die posteriori Chance zu beurteilen. Die Hypothesen lauten dann

$$H_o : s_i = s_i^* \quad H_1 : s_i = s_i^-. \quad (2.2.27)$$

Die posteriori Chance ergibt sich zu

$$o(s_i^*) = \frac{p(s_i^* | \mathbf{s}, \mathbf{d})}{p(s_i^- | \mathbf{s}, \mathbf{d})}. \quad (2.2.28)$$

Falls  $\mathbf{s}^*$  die beste Belegung des Knotens und  $\mathbf{s}^-$  die zweitbeste Klassifikation des Knotens  $i$  bedeutet, gibt die posteriori Chance ein Maß für die Sicherheit der Klassifikation an.

Zur Beurteilung der Stabilität der Gesamtklassifikation sollte das Maß auf den gesamten Klassifikationsraum übertragen werden

$$o(\mathbf{s}^*) = \frac{p(\mathbf{s}^* | \mathbf{d})}{p(\mathbf{s}^- | \mathbf{d})}. \quad (2.2.29)$$

Die zweitbeste Lösung der Gesamtklassifikation ist in der Regel aber schwierig zu finden.

- Als weiteres Kriterium lässt sich die durchschnittliche Klassifikationswahrscheinlichkeit über das geometrische Mittel der lokalen Wahrscheinlichkeiten angeben. Sie gibt über das gesamte Netz gesehen Aufschluss über die Homogenität der Klassifikation. Sie berechnet sich mit

$$\overline{p(s_i)} = \sqrt[n_p]{p(\mathbf{s})}, \quad (2.2.30)$$

wobei  $n_p$  die Anzahl der Zufallsvariablen im Netz ist.

## 2.3 Parameterschätzung und Modellklassifikation

### 2.3.1 Das Gauss-Markoff-Modell

Es sei  $\mathbf{y}$  ein Beobachtungsvektor,  $\boldsymbol{\beta}$  ein Vektor unbekannter fester Parameter und  $\mathbf{f}(\boldsymbol{\beta})$  die Abbildungsfunktion zwischen den beiden.  $D(\mathbf{y})$  sei die Kovarianzmatrix der Beobachtungen und bis auf einen unbekanntem Faktor  $\sigma^2$  als inverse Gewichtsmatrix  $\mathbf{P}^{-1}$  bestimmt. Dann bezeichnet man das Modell

$$\mathbf{f}(\boldsymbol{\beta}) = \mathbf{y} + \mathbf{e} \quad \text{mit} \quad D(\mathbf{y}) = \sigma^2 \mathbf{P}^{-1} \quad (2.3.1)$$

als Gauss-Markoff-Modell (GMM) (KOCH 1997, S. 166). Die erste Gleichung in Gleichung 2.3.1 wird als Beobachtungsgleichung bezeichnet. Die Schätzung der unbekanntem Parameter ergibt sich nach einer Linearisierung der Beobachtungsgleichung mit den unbekanntem Parametern  $\boldsymbol{\beta}$  an der Stelle  $\boldsymbol{\beta}_o$ . Sei  $\mathbf{X}$  die Jacobi-Matrix

$$\mathbf{X} = \left( \frac{\partial \mathbf{f}}{\partial \boldsymbol{\beta}} \Big|_{\boldsymbol{\beta}_o} \right). \quad (2.3.2)$$

Dann folgt die linearisierte Beobachtungsgleichung als

$$\mathbf{X} \Delta \boldsymbol{\beta} = \mathbf{y} - \mathbf{f}(\boldsymbol{\beta}_o) + \mathbf{e} \quad (2.3.3)$$

Die Schätzung der unbekanntem Parameter zu  $\boldsymbol{\beta}$  ergibt sich dann zu

$$\hat{\boldsymbol{\beta}} = \boldsymbol{\beta}_o + (\mathbf{X}^t \mathbf{P} \mathbf{X})^{-1} \mathbf{X}^t \mathbf{P} \mathbf{y} \quad (2.3.4)$$

und die Schätzung der Kovarianzmatrix der unbekanntem Parameter zu

$$D(\hat{\boldsymbol{\beta}}) = \frac{\Omega}{n - u} (\mathbf{X}^t \mathbf{P} \mathbf{X})^{-1} \quad (2.3.5)$$

mit

$$\Omega = (\mathbf{y} - \mathbf{f}(\hat{\boldsymbol{\beta}}))^t \mathbf{P} (\mathbf{y} - \mathbf{f}(\hat{\boldsymbol{\beta}})) \quad (2.3.6)$$



als Quadratsumme der Residuen.

In der Bayes-Statistik wird das GMM äquivalent zu Gl. 2.3.1 als

$$E(\mathbf{y}|\boldsymbol{\beta}) = \mathbf{f}(\boldsymbol{\beta}) \quad \text{mit} \quad D(\mathbf{y}|\sigma^2) = \sigma^2 \mathbf{P} \quad (2.3.7)$$

formuliert, wobei  $\boldsymbol{\beta}$  und  $\sigma$  als a priori unbekannte Parameter interpretiert werden. Die Beobachtungen seien normalverteilt mit

$$\mathbf{y}|\boldsymbol{\beta}, \sigma^2 \sim N(\mathbf{f}(\boldsymbol{\beta}), \sigma^2 \mathbf{P}), \quad (2.3.8)$$

wobei  $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  die Normalverteilung mit dem Erwartungswert  $\boldsymbol{\mu}$  und der Kovarianzmatrix  $\boldsymbol{\Sigma}$  bedeutet.

### 2.3.2 Parameterschätzung mit Restriktionen

Sollen die unbekannt geschätzten Parameter Restriktionen erfüllen, können diese als Restriktionsgleichungen

$$\mathbf{h}(\boldsymbol{\beta}) = \mathbf{0} \quad (2.3.9)$$

formuliert werden. Es ergibt sich das Gauss-Markoff-Modell mit Restriktionen (GMR):

$$\mathbf{f}(\boldsymbol{\beta}) = \mathbf{y} + \mathbf{e} \quad \text{mit} \quad \mathbf{h}(\boldsymbol{\beta}) = \mathbf{0} \quad \text{und} \quad D(\mathbf{y}) = \sigma^2 \mathbf{P}^{-1} \quad (2.3.10)$$

Nach der Linearisierung der Beobachtungsgleichung (s. Gl. 2.3.3) und den Restriktionen an der Stelle  $\boldsymbol{\beta}_o$

$$\mathbf{H}\Delta\boldsymbol{\beta} = -\mathbf{h}(\boldsymbol{\beta}_o) := \mathbf{w} \quad (2.3.11)$$

ergibt sich die Schätzung als Projektion der Schätzung des GMMs ohne Restriktionen in den Restriktionsraum als Lösung des Gleichungssystems

$$\begin{pmatrix} \mathbf{X}^t \mathbf{P} \mathbf{X} & \mathbf{H} \\ \mathbf{H}^t & \mathbf{0} \end{pmatrix} \begin{pmatrix} \hat{\boldsymbol{\beta}} \\ \mathbf{k} \end{pmatrix} = \begin{pmatrix} \mathbf{y} \\ \mathbf{w} \end{pmatrix} \quad (2.3.12)$$

Der Vektor  $\mathbf{k}$  ist der Vektor der Lagrange'schen Multiplikatoren der Optimierungsfunktion.

Die Dispersionsmatrix der geschätzten Parameter ergibt sich nach Gl. 2.3.6, wenn  $\hat{\boldsymbol{\beta}}$  durch  $\hat{\boldsymbol{\beta}}$  ersetzt wird. Die Restriktionen können dazu verwendet werden, Rangdefekte in der Bestimmung der unbekannt Parameter zu beseitigen oder auch um zusätzliche Restriktionen den zu schätzenden Parametern aufzuprägen. Im Falle der Beseitigung von Rangdefekten handelt es sich bei den Restriktionen um Datumsfestlegungen.

### 2.3.3 Das gemischte Schätzmodell

Es sei eine Beobachtungsgleichung  $\mathbf{g}(\boldsymbol{\beta}, \boldsymbol{\gamma}) = \mathbf{0}$  gegeben, wobei  $\boldsymbol{\beta}$  der Vektor der unbekannt festen Parameter und  $\boldsymbol{\gamma}$  der Vektor unbekannter Zufallsparameter sind (KOCH 1997, S. 231). Sei  $\mathbf{y}$  der Vektor der Beobachtungen.  $\sigma^2$  sei ein unbekannter Varianzfaktor und  $\boldsymbol{\Sigma}_{\boldsymbol{\gamma}\boldsymbol{\gamma}}$  die bekannte Dispersionsmatrix der Zufallsparameter. Dann gilt

$$\mathbf{g}(\boldsymbol{\beta}, \boldsymbol{\gamma}) = \mathbf{y} \quad \text{mit} \quad D(\boldsymbol{\gamma}) = \sigma^2 \boldsymbol{\Sigma}_{\boldsymbol{\gamma}\boldsymbol{\gamma}} \quad (2.3.13a)$$

$$\boldsymbol{\Sigma}_{\mathbf{y}\mathbf{y}} = \sigma^2 \mathbf{Z} \boldsymbol{\Sigma}_{\boldsymbol{\gamma}\boldsymbol{\gamma}} \mathbf{Z}^t, \quad (2.3.13b)$$

wobei  $\mathbf{Z}$  die Koeffizientenmatrix der Zufallsparameter an der Stelle  $\boldsymbol{\gamma}_o$  nach einer Linearisierung der Funktion  $\mathbf{g}$  ist. Das gemischte Modell kann zur Schätzung der unbekannt festen Parameter

auf eine Schätzung im GMM zurückgeführt werden. Die Schätzungen lauten dann:

$$\begin{aligned}\widehat{\beta} &= \beta_o + (\mathbf{X}^t \Sigma_{yy}^t \mathbf{X})^{-1} \mathbf{X}^t \Sigma_{yy}^{-1} \mathbf{y} \\ \widehat{\sigma^2} &= \frac{\Omega}{n - u} \\ D(\beta) &= \widehat{\sigma^2} (\mathbf{X}^t \Sigma_{yy}^t \mathbf{X})^{-1},\end{aligned}$$

wenn  $\mathbf{X}$  die Koeffizientenmatrix der unbekannt Parameter  $\beta$  an der Stelle  $\beta_o$  ist. Ein Schätzung der Zufallsparameter  $\gamma$  ist in dieser Arbeit nicht notwendig und wird deshalb auch hier nicht angeführt.

Bei Verwendung von Restriktionen muss das gemischte Modell erweitert werden.

$$\begin{aligned}\mathbf{X}\beta + \mathbf{Z}\gamma &= \mathbf{y} \quad \text{mit} \quad \mathbf{H}\beta = \mathbf{w} \quad \text{und} \\ D(\gamma) &= \sigma^2 \Sigma_{\gamma\gamma}\end{aligned}$$

Die Schätzung des Parametervektors ergibt sich dann aus dem Gauss-Markoff-Modell mit Restriktionen. Das modifizierte Gleichungssystem 2.3.12 lautet dann

$$\begin{pmatrix} \mathbf{X}^t \Sigma_{yy}^{-1} \mathbf{X} & \mathbf{H} \\ \mathbf{H}^t & \mathbf{0} \end{pmatrix} \begin{pmatrix} \Delta\beta \\ \mathbf{k} \end{pmatrix} = \begin{pmatrix} \mathbf{y} \\ \mathbf{w} \end{pmatrix}.$$

### 2.3.4 Beurteilung von Schätzern

Die bisher in diesem Abschnitt beschriebenen Schätzverfahren sind formuliert für zufällige Abweichungen der Beobachtungen von den Modellen und genügend genaue Linearisierungen der Modelle. Die zufälligen Beobachtungsfehler bewirken, dass mit den linearisierten Modellen gute Schätzungen für die wahren Parameter der Modelle gefunden werden.

In dieser Arbeit werden für die Rekonstruktion Schätzprozesse automatisch aus den Daten und der Klassifikation generiert. Diese Schätzprozesse gehören einzelnen Klassen von Schätzaufgaben an. Sie hängen jedoch von dem lokal klassifizierten Modell ab. Die zu verwendenden Daten werden automatisch aus der Gesamtmenge der Daten abgeleitet. Folgende Probleme können dabei auftreten:

- Verwendung des falschen Modells aufgrund der Fehlklassifikation
- Ableitung schlechter Näherungswerte
- Ausreißer in den Daten

Um den Einfluss großer Fehler dieser drei Arten in das Rekonstruktionsergebnis zu verhindern, muss das Schätzergebnis beurteilt werden und möglicherweise verworfen werden.

Die Beurteilung der Schätzer und deren Ergebnisse findet in dieser Arbeit in drei Formen statt:

- Beurteilung der Beobachtungen, ob sie zu dem klassifizierten und angenommenen Modell passen: Durch die Beurteilung der Daten vor der Schätzung sollen die Auswirkungen von Ausreißern in den Daten oder ungenauen Abgrenzungen der Menge der zu berücksichtigenden Daten reduziert werden.
- Beurteilung der Modelle, ob sie zu den ausgewählten Beobachtungen gepasst haben: Ursache für diesen Fehler kann ein fehlerhaftes Nachbarschaftsmodell sein.
- Kombination der Schätzergebnisse mit den Näherungswerten.

Auf die Beurteilung der Beobachtungen wird im Abschnitt 2.5 eingegangen. Zur Beurteilung der Modelle wird die geschätzte Varianz der Gewichtseinheit  $\hat{\sigma}^2$  herangezogen. Mittels eines Hypothesentest der Varianz der Gewichtseinheit kann über die  $\chi^2$ -Verteilung eine erwartete maximal

zulässige Varianz der Gewichtseinheit  $\sigma_{max}^2$  in Abhängigkeit von der Redundanz und eines Signifikanzniveaus angegeben werden. Gilt

$$\hat{\sigma}^2 > \sigma_{max}^2 \quad (2.3.14)$$

wird die Schätzung verworfen. Dann werden keine Korrekturen an die Näherungsrepräsentation angebracht. In dieser Arbeit wurde ein

$$\sigma_{max}^2 = 3\sigma^2$$

angenommen. Hier wurde auf die Verwendung eines Hypothesentests verzichtet, um einen von der Redundanz unabhängigen Schwellwert anzugeben. Teilweise werden für die Bestimmung der Dreiecke in der Arbeit aufgrund der großen Anzahl von Laserbeobachtungen sehr hohe Redundanzen erreicht. Der Faktor ist so gewählt, dass nur stark abweichende Modelle, bei denen ein fehlerhaftes Modell angenommen werden kann, abgelehnt werden.

Wird die Schätzung nicht verworfen, sollten die Näherungswerte unter Verwendung der Klassifikationswahrscheinlichkeiten des Modells korrigiert werden. Sei  $\beta_o$  der Vektor der Näherungswerte der unbekannt Parameter und  $p(\beta_o)$  die Klassifikationswahrscheinlichkeit des Modells.  $\hat{\beta}$  sei die Schätzung und  $p(\hat{\beta})$  die resultierende Klassifikationswahrscheinlichkeit. Dann lassen sich die korrigierten Parameter über das gewogene Mittel angeben. Sei  $s^*$  die Klassifikation. Dann gilt

$$\hat{\beta}|s^* = \frac{p(s^*|\beta_o)\beta_o + p(s^*|\hat{\beta})\hat{\beta}|s^*}{p(s^*|\beta_o) + p(s^*|\hat{\beta})}. \quad (2.3.15)$$

In dieser Arbeit wird ein von der Wahrscheinlichkeit unabhängiger Ansatz zur Korrektur der Parameter verwandt: Die Näherungswerte werden um einen Bruchteil der Differenz zwischen der Schätzung und den Näherungswerten korrigiert.

$$\hat{\beta}|s^* = \alpha\beta_o + (1 - \alpha)\hat{\beta}|s^* \quad (2.3.16)$$

Die Schrittweite  $\alpha$  wird üblicherweise als 0.5 angenommen. Mit dieser Wahl der Schrittweite wird eine vorsichtige Korrektur der Näherungswerte erreicht. Der wahre Wert für die zu bestimmenden Parameter kann jedoch nicht erreicht werden. Eine Annäherung ist jedoch beliebig genau möglich. Diese Approximation inklusive der daraus resultierenden langsamen Konvergenz der Schätzer reicht für die beschriebene Anwendung jedoch aus.

## 2.4 Beschreibungslänge

Das Prinzip der Minimalen Beschreibungslänge (MDL<sup>10</sup>) ermöglicht die gleichzeitige Schätzung der Anzahl der Parameter und der Parameter selbst ohne separate Hypothesentests. Dieser Ansatz kann als kodierungstheoretische Formulierung früher philosophischer Ansätze angesehen werden. Wie William von Ockham schon Anfang des 13. Jahrhunderts forderte<sup>11</sup>, bevorzugt MDL die einfachste der möglichen Lösungen.

Viele unterschiedliche Formen der Beschreibungslänge sind von Autoren vorgeschlagen worden. Eine Übersicht über die unterschiedlichen Formen gibt TORR 1997. Wir verwenden die Definition von RISSANEN 1987. Er definiert die Beschreibungslänge aus dem Hintergrund der Informationstheorie als die Anzahl der zur Kodierung des Ergebnisses notwendigen *bits*.

Die Beschreibungslänge nach RISSANEN 1987 berechnet sich aus

$$BL = \frac{u - r}{2} \log_2(n) + \frac{\Omega}{2 \log_e(2)},$$

wenn  $u - r$  der Freiheitsgrad,  $n$  die Anzahl der Beobachtungen und  $\Omega$  die Quadratsumme der Abweichungen der Beobachtungen vom Modell sind. Der Freiheitsgrad entspricht bei Problemen ohne Restriktionen der Anzahl der unbekannt Parameter.

<sup>10</sup> engl. *Minimal Description Length*

<sup>11</sup> Unter der Bezeichnung *Ockham's Rasierklänge* ist die Regel "non sunt multiplicanda entia praeter necessitatem" in die Naturwissenschaft und Philosophie eingegangen, nach der aus einer Menge möglicher Erklärungen oder Lösungen eines Problems immer die einfachste ausgewählt werden soll.

## 2.5 Robuste Schätzung

In dieser Arbeit werden ausschließlich robuste Schätzverfahren verwandt. Neben der Bestimmung der unbekanntenen wahren Parameter selektieren robuste Schätzer –unter Modellannahmen– nicht gültige Beobachtungen aus.

HUBER 1981 stellt die folgenden drei Anforderungen an robuste Schätzer:

1. Sie sollen eine vernünftige (eine optimale oder fast optimale) Effizienz für das angenommene Modell haben.
2. Sie sollen “robust” in dem Sinne sein, dass kleine Veränderungen in den Modellannahmen nur kleine Auswirkungen auf die Performance des Schätzers haben und die Schätzwerte nahe bei den wahren Werten liegen.
3. Große Fehler des Modells sollen keine “Katastrophe” für den Schätzer bewirken.

Es wurden in der Vergangenheit verschiedene robuste Schätzer vorgeschlagen (z. B. FISCHLER UND BOLLES 1981, HUBER 1981, ROUSSEEUW UND LEROY 1987, KOCH 1997, S. 277ff). Robuste Schätzer sind im Allgemeinen iterativ, dabei werden fehlerhafte Beobachtungen oder Beobachtungsgruppen heruntergewichtet oder ausgesondert, und dadurch die Daten<sup>12</sup> bereinigt. In dieser Arbeit wird ein Schätzer mit Regewichtung verwandt, der deshalb hier kurz beschrieben werden soll.

Für die Schätzungen in dieser Arbeit stehen bereits Näherungswerte zur Verfügung, sodass die Suche nach geeigneten Näherungswerten unterbleiben kann. Es sind jedoch nicht gewünschte Auswirkungen von fehlerhaften oder falsch selektierten Beobachtungen zu erwarten. Diese Beobachtungen werden unter Annahme der hinreichenden Richtigkeit der Näherungswerte herausgefiltert.

Der Vektor  $\mathbf{y}$  sei der Vektor der Beobachtungen, dem eine Gewichtsmatrix  $\mathbf{P}$  zugeordnet ist. Es liege bereits eine Schätzung oder eine Näherung der unbekanntenen Parameter  $\beta_o$  vor. Mittels der Beobachtungsgleichung lassen sich Beobachtungen für die  $\beta_o$  prognostizieren. Es ergibt sich der prognostizierte Beobachtungsvektor  $\bar{\mathbf{y}}$ . Aufgrund der Abweichungen zu dem tatsächlichen Beobachtungsvektor  $\mathbf{y}$  wird die Gewichtsmatrix  $\mathbf{P}$  zu  $\bar{\mathbf{P}}$  verändert. Für eine nicht diagonale Gewichtsmatrix  $\mathbf{P}$  lauten dann die Elemente

$$\bar{p}_{ij} = p_{ij}g(y_i - \bar{y}_i, y_j - \bar{y}_j), \quad (2.5.1)$$

wobei  $g(a, b)$  eine Gewichtsfunktion ist, die für kleine Abweichungen in den Beobachtungen den Wert 1 annimmt und für große Abweichungen gegen 0 strebt. In dieser Arbeit wurde eine diagonale Gewichtsmatrix gewählt. Die Gewichtsfunktion ist eine binäre Funktion, die oberhalb eines Schwellwertes für die Residuen durch ein Gewicht von 0 Beobachtungen aus der Menge der Beobachtungen löscht.

Aufgrund der Annahme der Richtigkeit der Näherungswerte kann dieser Schätzer mit einem hohen Prozentsatz von Ausreißern umgehen. Es dürfen jedoch nur so viele Beobachtungen gelöscht werden, dass die Bestimmbarkeit der unbekanntenen Parameter erhalten bleibt. Werden mehr Beobachtungen gelöscht, muss das gewählte Modell in Frage gestellt werden. Die Gültigkeit des Modells und damit der Klassifikation lässt sich jedoch nicht ausschließlich aufgrund der Datenanalyse klären.

<sup>12</sup>Daten können hier auch angenommene Restriktionen sein.

## Kapitel 3

# Interpretation und Rekonstruktion von Gebäuden

Ziel dieser Arbeit ist die Formulierung und Umsetzung eines Verfahrens zur integrierten Interpretation und Rekonstruktion von Gebäuden, das für die Verwendung multisensorieller Daten geeignet ist (s. Abs. 1.5).

Diese Problemstellung ist Teil eines mehrschrittigen Prozesses, der notwendig ist, um von den Sensordaten ausgehend, zu einer vollständigen und effizienten Gebäudebeschreibung zu gelangen. Die Aufgabe der Rekonstruktion und Interpretation läßt sich in drei wesentliche Teilschritte gliedern:

1. die Überführung der Sensordaten in eine symbolische Repräsentation (Vorinterpretation),
2. die Interpretation und Rekonstruktion der symbolischen Struktur und
3. die Überführung der interpretierten und rekonstruierten symbolischen Gebäudebeschreibung in eine abschliessende Gebäudedarstellung (Aggregation)

Der Schritt der Überführung der Daten in eine symbolische Repräsentation generiert aus den Daten eine Näherungsrepräsentation (Näherungsoberfläche). Diese Arbeit konzentriert sich auf den zweiten Schritt, obwohl im folgenden Kapitel ein Vorgehen für die Gewinnung der symbolischen Repräsentation angegeben wird. In diesem Kapitel wird dazu das allgemeine Verfahren zur Interpretation und Rekonstruktion symbolischer Daten vorgestellt.

Die Rekonstruktion von Gebäuden meint hier nicht nur die geometrische Rekonstruktion, sondern auch die Rekonstruktion anderer Eigenschaften des Gebäudes wie z. B. der Farbe, der Textur oder des Reflexionsverhalten. Ziel ist also eine Rekonstruktion in den unterschiedlichen Erscheinungsformen der Gebäude.

Die Interpretation wird zunächst auf einem CW-Komplex formuliert. In dieser Formulierung entwickelt der Ansatz sein größtes Potential. In Kapitel 4 wird die Repräsentation als triangulierte Oberfläche für Laserscannerdaten angewandt.

In den folgenden Abschnitten dieses Kapitels werden das Objektmodell, das Beobachtungsmodell, die Modellierung von unterschiedlichen Gebäudetypen und die Lösungsstrategie für die Interpretation und die Rekonstruktion beschrieben.<sup>12</sup>

---

<sup>1</sup>Im Unterschied zu dem folgenden Kapitel wird hier als Gebäuderepräsentation ein Polyedermodell gewählt. Die Triangulation in Kapitel 4 wird dann als Spezialisierung verwandt. Typen von Sensordaten werden nur beispielhaft in diesem Kapitel genannt. Die Fokussierung auf die Laserdaten erfolgt erst in dem genannten Kapitel.

<sup>2</sup>Ergänzende Erläuterungen können in BRUNN 2000A gefunden werden.

### 3.1 Das Gebäudemodell

Zentrales Element des in dieser Arbeit vorgeschlagenen Verfahrens ist die Repräsentationsstruktur und Modellierung des Objektes "Gebäude".

Es wird als Repräsentationsstruktur eine abstrakte Polyederstruktur gewählt. "Abstrakt" heißt, dass die Polyederstruktur eine geometrische Realisierung haben kann, aber auch ohne die geometrische Realisierung das Gebäude repräsentieren kann. So lässt sich ein Gebäude z. B. auch durch verknüpfte Punkte darstellen, die die Bedeutungen "Firsteckpunkt" (2 Stück), "Traufeckpunkt" und "Bodeneckpunkt" (jeweils 4 Stück) haben (s. Abb. 3.1). In Abschnitt 3.1.1 wird auf




Abbildung 3.1: Visualisierung der Geometrie und Topologie des Walmdachhauses. (FEP=Firsteckpunkt, TEP=Traufeckpunkt, BEP=Bodeneckpunkt)

diese abstrakte Repräsentationsstruktur mittels der Topologie der Polyederoberfläche für allgemeine Objekte näher eingegangen. In Abschnitt 3.1.1 wird sie dann für Gebäude präzisiert.

Das Modell für ein allgemeines Haus ist noch nicht bekannt. Erst wenige Arbeiten haben empirische oder theoretische Untersuchungen unternommen, welche Eigenschaften ein Haus haben muss und was ein Haus ausmacht. Die Arbeiten von Englert (ENGLERT UND CREMERS 1997; ENGLERT 1997) sind ein Anfang, beziehen sich jedoch nur auf einen Datensatz und auf eingeschränkte Aspekte. Die Entwicklung der Methodik steht dort im Vordergrund.

Wesentliches Merkmal des Modellierungsansatzes mit CW-Komplexen ist die weitgehende Anwendungsunabhängigkeit. Schon WALKER *et al.* 1990 forderte für ein Interpretationssystem die Anwendungsunabhängigkeit. Er sah aber die Notwendigkeit der Anbindung von anwendungsspezifischer Information im Falle der Verwendung des Systems vor. Wir wollen noch einen Schritt weitergehen. Wenn das allgemeine Interpretationssystem den Anforderungen einer Anwendung nicht genügt, bedarf es der Erweiterung des Wissenkerns. Dies führt auf große Wissensbasen, deren Wissen wiederum nicht von allen Anwendungen benötigt wird. So entstehen weitere Anforderungen an die Wissensrepräsentation.

Die Anforderungen, dass das System auswählt, welcher Teil des ihm bekannten Wissens relevant für die Lösung des Problems ist, und dass es aufgrund des vorhandenen Modellwissens den Interpretationsprozess optimiert, müssen an ein solches System gestellt werden. Dazu werden Techniken, z. B. im Bereich der *Constrained-Logic-Programming* (s. KOLBE *et al.* 1999) entwickelt, die mit zunehmendem Wissen die Effizienz der Algorithmen steigern können.

In Ermangelung eines allgemeinen Gebäudemodells wird in dieser Arbeit ein Satz von Modellen von Gebäudeprimitiven verwandt. Das Nachbarschaftswissen der Modelle wird automatisch aus repräsentativen Gebäudebeschreibungen gelernt. Das Likelihood-Wissen kann überwiegend gebäudetypunabhängig modelliert werden.

Notwendig für die Berücksichtigung der unterschiedlichen Datenquellen und Teilergebnisse von unterschiedlichen Auswerteprozessen innerhalb der Rekonstruktion ist eine semantische Modellierung des Gebäudes und seiner Teile (STEINHAGE 1999). Sinnvoll ist eine Strukturierung des Begriffs "Gebäudes" anhand seiner Semantik.

Wir wählen also in dieser Arbeit ein semantisches Gebäudemodell, das auf der Topologie des Gebäudes formuliert ist.

### 3.1.1 Allgemeines Objektmodell

Gebäude lassen sich durch eine Polyedertopologie beschreiben. Diese wird nun zur Definition eines allgemeinen Objektmodells, des polymorphen Polyeders, ausgenutzt. Es führt auf eine topologische Repräsentation, was eine referenzsystemlose Darstellung losgelöst von äußeren geometrischen oder radiometrischen Koordinatensystemen meint. Das Gebäude wird mit einer topologischen Repräsentation durch eine Menge von Zellen  $S$ , die durch Verknüpfungsvorschriften  $\mathcal{V}(S)$  aneinander geheftet sind, repräsentiert<sup>3</sup>.

Die Zellen sind die Basiselemente der Repräsentation. Zellen können nach Abs. 2.1.2 Punkte, Kanten und Flächen sein. Es gelten die dort gewählten Bezeichnungen.

Sie hängen mit lokalen Eigenschaften des Objektes zusammen: Es wird angenommen, dass über die gesamte Zelle am Gebäude konstante Eigenschaften herrschen.

Die Zellen sind in der bisherigen Definition abstrakte Größen. Semantische, radiometrische oder geometrische Information wird den Basiselementen der Objektrepräsentation, den Zellen als Attribute hinzugefügt. Aufgrund der assoziierten Information können später den Zellen Klassen zugewiesen werden.

Die Menge der möglichen Klassifikationen muss a priori definiert werden. Die Definition ist dabei auf unterschiedlichen Beschreibungsebenen möglich: z. B. radiometrisch, geometrisch oder semantisch. In diesem Kapitel wird die semantische Beschreibung bevorzugt. Im Kapitel 4 wird dann die semantische Beschreibung auf eine geometrische spezialisiert.

Objektteile zeichnen sich durch unterschiedlich dimensionale Ausprägungen aus: z. B. eine Gebäudewand ist ein zweidimensionales Objekt, die Firstlinie hat eine eindimensionale Ausprägung und der Giebeleckpunkt ist nulldimensional. Daher muss eine topologische Repräsentation gewählt werden, die die Repräsentation unterschiedlicher Objektdimensionen möglich macht. Zellen erfüllen diese Anforderungen.

Um die unabhängige Betrachtung aller drei Zellentypen zu verdeutlichen, wird ein Graph definiert, der aus dem CW-Komplex abgeleitet wird. In diesem werden alle Zellen in Knoten überführt. Die Verkantung entsteht aus dem folgenden Nachbarschaftsprinzip auf dem CW-Komplex:

- Flächen-Zellen (2-Zellen) sind mit ihren umgebenden Kanten-Zellen (1-Zellen) benachbart.
- Kanten-Zellen (1-Zellen) sind zu ihren Endpunkte (0-Zellen) benachbart.

Die Nachbarschaften seien symmetrisch.

**Definition 3.1.1 (Polymorphes Polyeder)** *Eine Polyederrepräsentation, in der alle Zellen (Punkte, Kanten und Flächen) explizit modelliert sind, wird als Polymorpher Polyeder bezeichnet. Zwischen benachbarten Zellen werden Nachbarschaftsverbindungen gesetzt.*

Die unterschiedlichen Ebenen der topologischen Repräsentation der Gebäude (hier sind es drei) sind statistisch von einander abhängig, da durch Kenntnis bestimmter geometrischer und radiometrischer Erscheinungen bestimmte semantische Klassifikationen favorisiert werden können. Eine Repräsentation dieser Abhängigkeiten stellen Bayes-Netze (PEARL 1988) dar (s. Abb. 3.2).

Das bis hier hin eingeführte Polyedermodell ist noch unabhängig von der Objektart. Einzige Voraussetzung ist die Repräsentierbarkeit des Objekts CW-Komplex mit 0-, 1- und 2-Zellen. Jetzt soll durch die Wahl der Semantik der Basiselemente die Vielfalt der beschreibbaren Modelle eingeschränkt werden. Die Rekonstruktion und Interpretation soll später interpretierte Gebäudedatensätze liefern. Daher wird die Modellierung nun auf für Gebäude relevante Aspekte eingeschränkt.

<sup>3</sup>DELINGETTE 1999 hat unabhängig von der Entwicklung der Repräsentation für die Gebäude eine Objektrepräsentation auf Grundlage der Simplicialen Komplexe eingeführt. Er nutzt diese Repräsentation zur Darstellung und Optimierung der Oberflächengeometrie.

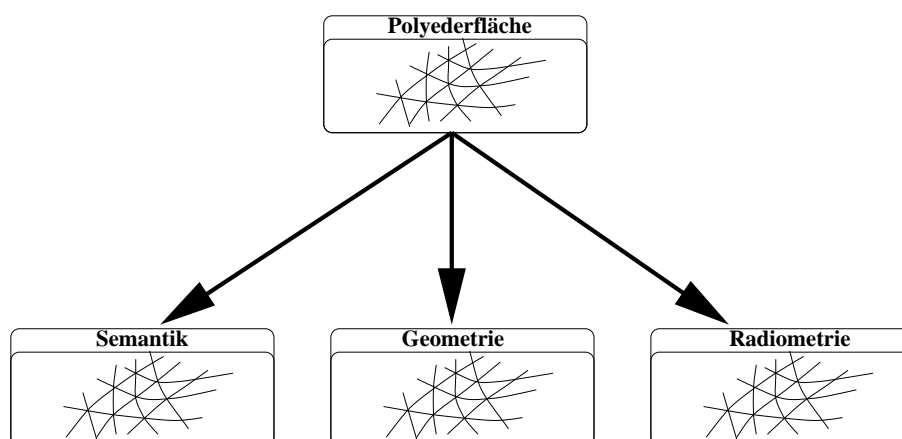


Abbildung 3.2: Relation der abstrakten Objektrepräsentation zur Semantik und den geometrischen und radiometrischen Ausprägungen.

### 3.1.2 Das semantische Gebäudemodell

Gebäude setzen sich aus einer Menge von Objektteilen zusammen (FISCHER *et al.* 1998). Diese Objektteile haben semantische oder funktionelle Bedeutungen für das Gebäude. Es handelt sich dabei z. B. um Bestandteile des Daches, der Wände, des Schornsteins oder des Giebels. Diese anthropogenen Bezeichnungen  $\bar{K}$  der Gebäudeteile werden Ausgangspunkt der Gebäudemodellierung sein.

Zur Repräsentation sei ein polymorpher Polyeder (s. Def. 3.1.1) gewählt. Die grundlegenden Strukturen der Gebäudebeschreibung sind also Punkte, Kanten und Flächen eines abstrakten Polyeders, die unter Berücksichtigung der topologischen Bedingungen zu Gebäudeoberflächen verknüpft werden. Punkte, Kanten und Flächen können auf einer semantischen Ebene unterschiedliche Bedeutungen für das Gebäude annehmen. Diese Bedeutungen sind in Modelllisten definiert. Klassifikationsabhängigkeiten sind durch bedingte Wahrscheinlichkeiten definiert.

In dieser Arbeit betrachten wir Grundstrukturen der Gebäude. Für die Grundstrukturen handelt es sich bei den Basiselementen um eine relativ eng begrenzte Menge von Klassen. Die Anzahl der Modellklassen lässt sich leicht erweitern, um Aufbauten auf Dächern wie z. B. Kamine, Fenster, Gauben und Antennen zu berücksichtigen.

Die Punkte des polymorphen Polyeders des Gebäudes können die folgenden Bedeutungen annehmen. Die Klassen sind dabei nach der Anzahl der sich treffenden Ebenen der Gebäudeoberflächenbeschreibung in dem Punkt sortiert:

- eine Ebene: Dachflächenpunkt (DP), Wandflächenpunkt (WP), Bodenflächenpunkt (BP),
- zwei Ebenen: Firstkantenpunkt (FKP), Giebelkantenpunkt (FKP), Traufkantenpunkt (TKP), Bodenkantenpunkt (BKP), Verbindungskantenpunkt (VKP),
- drei und mehr Ebenen: Traufkanteneckpunkt (TKP), Firsteckpunkt (FEP), Bodeneckpunkt (BEP), Verbindungfirstpunkt (VFP), Verbindungstraufkantenpunkt (VTP).

“Verbindungen” entsprechen den zur Beschreibung der in FISCHER *et al.* 1997 definierten Konnektoren (s. Abb. 3.3). Das führt zu 13 unterschiedlichen Bedeutungen. Die Klassen werden mit  $K_{pi}$  mit  $i \in \{1 \dots 13\}$  bezeichnet.

Kanten eines Graphen können die folgenden Bedeutungen annehmen:

- für eine Ebene: Dachflächenkante (DK), Wandflächenkante (WK) und Bodenflächenkante (BK),






Abbildung 3.3: Komplexes Walmdachhaus mit Verbindungsknoten und Verbindungskanten.

- für zwei Ebenen: Traufkante (TK), Giebelkante (GK), Firstkante (FK), Bodenkante (BK), aufgehende Kante (AGK), Verbindungskante (VK).

Das sind in der Summe neun unterschiedliche Klassen. Die Klassen werden mit  $K_{ki}$  mit  $i \in \{1 \dots 9\}$  bezeichnet.

Polyederseiten können die Bedeutungen Dachfläche (DF), Wandfläche (WF) und Bodenfläche (BF) annehmen. Die drei Klassen werden mit  $K_{di}$  mit  $i \in \{1 \dots 3\}$  bezeichnet.

Entsprechend der Repräsentationsstufe können also die Zellen unterschiedliche Bedeutungen (Klassen) annehmen. In Kapitel 4 wird dieses Modell auf ein geometrisches verallgemeinert. Auf der radiometrischen Repräsentationsebene wären Farbklassen zu definieren.

### 3.1.3 Statistisches Gebäudewissen

Nachdem in den vorangegangenen Abschnitten die Repräsentationsstruktur und die semantische Modellierung beschrieben wurde, wird in diesem Abschnitt Wissen über die Wechselbeziehungen zwischen den semantischen Klassen und Wissen über die Beobachtbarkeit von Eigenschaften in den Sensoren eingeführt. Wissen wird in zwei Formen in das Verfahren integriert:

1. als Likelihood-Wissen: Das Likelihood-Wissen ist Wissen über die Beziehungen der Klassifikationsmodelle zu den Daten der unterschiedlichen Sensoren. Die Beziehungen werden später mit bedingten Wahrscheinlichkeiten oder Wahrscheinlichkeitsverteilungen modelliert. Den verschiedenen Klassen der Zufallsvariablen werden Erscheinungsformen in den Daten zugewiesen: z. B. Traufkanten müssen eine bestimmte geometrische Form aufweisen oder die unterschiedlichen radiometrischen Erscheinungen können unterschiedlichen Klassen zugeordnet werden.
2. als Nachbarschaftswissen: Zulässige oder wahrscheinliche Nachbarschaftsklassifikationen werden festlegt: z. B. ist eine direkte Nachbarschaft von einem Giebel und einem Teil des Grundrisses unwahrscheinlich.

Das Nachbarschaftswissen wird als statistisches Wissen über Häufigkeiten eingeführt. Über die Wechselbeziehungen zwischen semantischen Klassifikationen sollen auch unterschiedliche Gebäudetypen unterschieden werden.

Daher stellen die lokale und die globale Klassifikationsaufgabe (s. Abs. 3.5) Anforderungen an das Gebäudemodell. Die Wahl der bedingten Wahrscheinlichkeiten wird daher durch zwei Kriterien beeinflusst:

1. Die Modellbeschreibung muss eine Klassifikation der einzelnen Beschreibungselemente der Repräsentation ermöglichen.
2. Die Modellbeschreibung muss gleichzeitig eine Trennung zwischen den verschiedenen Gebäudetypen gewährleisten.

Auf dem Polyeder definieren wir Nachbarschaften für die unterschiedlichen Knotentypen wie folgt:

- Ein Knoten vom Typ "Punkt" ist benachbart zu allen abgehenden Kanten, zu deren Endpunkten, einschließlich der dort abgehenden Kanten mit Endpunkten. Abbildung 3.4<sup>4</sup> zeigt die Nachbarschaftsstruktur des Knotens.
- Ein Knoten vom Typ "Kante" ist benachbart zu ihren Endpunkten, zu allen an den Endpunkten der Kante abgehenden Kanten und deren Endpunkten, zu allen Kanten der beiden Flächen, die auf einer Seite durch die Kante begrenzt werden, und allen anderen Kanten dieser Flächen. Abbildung 3.5<sup>4</sup> zeigt die Nachbarschaftsstruktur der Kante.
- Eine Knoten vom Typ "Fläche" ist benachbart zu allen angrenzenden Kanten einschliesslich ihrer Endpunkte und zu allen Flächen, die von diesen Kanten auf einer Seite begrenzt werden. Abbildung 3.6<sup>4</sup> zeigt die Nachbarschaftsstruktur der Fläche.




Abbildung 3.4: Nachbarschaftsstruktur des Knotens.




Abbildung 3.5: Nachbarschaftsstruktur der Kante.

Aus dieser Nachbarschaftsdefinition lassen sich Cliques (s. Def. 2.4) ableiten. Für Punktnachbarschaften sind in Abbildung 3.7 die Cliques bis zur vierten Ordnung dargestellt. Aus der Gesamtzahl der Cliques wird nur eine Teilmenge ausgewählt:

- Für Punkte wird die Clique verwendet, die den Punkt selbst und die abgehenden Kanten einschliesslich ihrer Endpunkte enthält.
- Für Kanten werden zwei Cliques ausgewählt. Die eine Clique besteht aus der Kante, ihren Endpunkten und den beiden Flächen, die die Kante auf einer Seite begrenzt. Die zweite Clique besteht aus der Kante und allen anderen Kanten, die die beiden Flächen begrenzen, die auch die Kante auf einer Seite begrenzt.

<sup>4</sup>Kreise bezeichnen die 0-Zellen, Kreuze die 1-Zellen und Dreiecke die 2-Zellen. Die Farben dienen zur Verdeutlichung der Segmente.




Abbildung 3.6: Nachbarschaftsstruktur der Fläche.




Abbildung 3.7: Darstellung aller Cliquentypen in der Nachbarschaft von Punkten bis zur vierten Ordnung: a) 1. Ordnung, b) 2. Ordnung, c) 3. Ordnung, d) 4. Ordnung.

- Für Flächen wird die Clique ausgewählt, die alle die Fläche begrenzenden Kanten enthält.
- Diese Cliques sind in Abbildung 3.8 dargestellt. Sie sind durch die vorangehende Nachbarschafts-




Abbildung 3.8: Nachbarschaften auf einem Polyeder für Punkte, Kanten und Flächen

definition beschreibbar. Die formale Ordnung der Cliques hängt von der Kardinalität der Punkte und der Anzahl der begrenzenden Kanten der Flächen ab. Die Ordnung der verwandten Kantenclique ist, wenn von dem Punkt  $k$  Kanten abgehen,  $2k + 1$ , da diese Clique  $2k + 1$  Elemente enthält. Die Ordnung der Clique ist aber für die Auswertung nicht von Bedeutung. Die Auswahl der zur Interpretation verwandten Cliques wurde aus folgenden Überlegungen getroffen, um mit möglichst wenig Cliques die Interpretationsaufgabe lösen zu können.

- Die Klassifikation von Punkten hängt im wesentlichen von der Funktion der abgehenden Kanten ab. So kann der Punkt z. B. nur als Traufkantenpunkt oder als Traufkanteneckpunkt klassifiziert werden, wenn zwei der abgehenden Kanten als Traufkantenpunkte klassifiziert wurden. Die Berücksichtigung der Klassifikation der abgehenden Kanten führt direkt auf eine große Einschränkung der wahrscheinlichen Klassifikationen.

Die Endpunkte der Kanten werden berücksichtigt, um Ketten von Eckpunkten (z. B. Traufkanten- oder Grundrisseckpunkte) zu vermeiden. Eine direkte Nachbarschaft von zwei Eckpunkten gleichen Typs kann verhindert werden.

- Die Klassifikation von Kanten hängt im wesentlichen von den Klassifikationen der benachbarten Flächen ab. Haben z. B. benachbarte Flächen unterschiedliche Klassifikationen, liegt wahrscheinlich ein Kantentyp vor, der den Übergang zwischen zwei Funktionen markiert (z. B. Traufkante, oder Grundrisskante). Die Berücksichtigung der anderen Kanten, die die benachbarten Flächen begrenzen, ermöglicht die Wahrung einer Kontinuität der Kantensklassifikationen. Widersprüchliche Klassifikationen in der Begrenzung einer Fläche können so unwahrscheinlicher auftreten.
- Die Klassifikation von Flächen hängt von den Klassifikationen der die Fläche begrenzenden Kanten ab. Zum Beispiel werden Wände durch Grundriss- und Traufkanten wie auch aufgehende Kanten begrenzt; Dachflächen jedoch nur durch Traufkanten, Firstkanten und Giebelkanten.

Die Auswirkungen der Cliquenauswahl auf das Ergebnis hängen jedoch noch von den mit diesen Cliques assoziierten bedingten Wahrscheinlichkeiten ab. Die Auswahl und Begründung der Cliques spiegelt jedoch wider, dass die bedingten Wahrscheinlichkeiten der gewählten Cliques eine differenzierende Wirkung auf die Klassifikation haben. Die bedingten Wahrscheinlichkeiten werden durch das im folgenden Abschnitt beschriebene Lernverfahren ermittelt.

### 3.1.4 Lernen von bedingten Wahrscheinlichkeiten

Es sei die Klassifikation der Knoten, Kanten und Flächen einer Polyederdarstellung eines repräsentativen Datensatzes für einen Gebäudetyp gegeben. Dann lassen sich die bedingten Modellwahrscheinlichkeiten für diesen Gebäudetyp aus der Polyederdarstellung durch Abzählen ableiten.

Generieren lässt sich die Klassifikation aus einer repräsentativen Gebäudebeschreibung mit kleinen Lagevarianzen in den Knoten, wenn angenommen wird, dass das likelihood-Wissen bekannt ist. Die Klassifikationen der Zufallsvariablen werden über eine Likelihood-Schätzung bestimmt, indem nur die Likelihood-Verteilung optimiert wird. Das Klassifikationsergebnis wird nachfolgend für den Lernschritt betrachtet. Die unterschiedlichen lokalen Konstellationen der Zufallsvariablen werden gezählt. Die Verteilung der gezählten Anzahlen ist proportional zur Wahrscheinlichkeitsverteilung.

### 3.1.5 Likelihoodwissen

Die Datenanalyse wird auf den mit dem Basiselement der Objektbeschreibung verknüpften Daten durchgeführt. Die Daten werden analysiert und mittels Wahrscheinlichkeitsverteilungen bewertet. Hier können unterschiedliche Datenquellen ausgewertet werden; z. B. auch Digitale Oberflächenmodelle oder Luftbilder.

Etwas allgemeiner lässt sich das so beschreiben: Die zu interpretierende generalisierte Oberflächenbeschreibung setzt sich aus Teilstrukturen zusammen, die Teil eines Gebäudes oder auch seiner Umgebung sein können. Die unterschiedlichen Teilstrukturen sind charakterisiert und in Klassen eingeteilt. Zur Identifikation und Einordnung dieser Teilstrukturen werden unterschiedliche Datenquellen  $D_1, \dots, D_d$  mit den Datenvektoren  $\mathbf{d}_1, \dots, \mathbf{d}_d$  verwendet. Die Informationsquellen werden durch unterschiedliche von der Datenart abhängige Filter evaluiert, die beobachtbare Daten in interpretierte Information umwandeln (s. Abb. 3.9); z. B. kann die Ausrichtung der Polyederoberfläche analysiert werden und zu Aussagen über die Vertikalität oder Horizontalität der Fläche führen oder die Helligkeit eines beobachteten Segments im Bild kann bei bekanntem Reflexionsmodell ebenfalls eine Aussage über die Neigung der Fläche liefern.

Die Verknüpfung der unterschiedlichen Datenquellen kann dabei aufwendig sein. Handelt es sich z. B. um Luftbilder, müssen in den Bildern extrahierte Merkmale wie Punkte, Kanten und Blobs der Näherungsgebäudedarstellung zugeordnet werden. Dieser Matchingprozess soll hier jedoch nicht behandelt werden, stellt aber eine noch nicht allgemein gelöste Aufgabe der symbolischen Auswertung von flächenhaften Daten dar<sup>5</sup>. Die Behandlung dieses Themas kann in dieser Arbeit für die Realisierung ausgelassen werden, da die symbolische Näherungsbeschreibung des Gebäudes direkt aus dem Digitalen Oberflächenmodell gewonnen wurde und so eine direkte Transformation von der symbolischen Beschreibung und zu den flächenhaften Oberflächendaten besteht (s. Kap. 4).

Die Beobachtungsmodelle sind bei der Annahme unabhängiger Beobachtungen  $\mathbf{y}$  nach Gleichung 3.3.7 als Verteilung

$$p(\mathbf{y}|s) \tag{3.1.1}$$

definiert. Beispielhaft sollen hier nun die Verteilungen für einige Beobachtungstypen skizziert werden.

- **Für beobachtete Gradienten im Bild:** Die Verbindung von symbolischen Kanten mit dem Bild wird in u. a. KOLLNIG UND NAGEL 1997 beschrieben. Es wird angenommen, dass die Kanten in dem Gradientenbild als Gaussfunktionen modellierbar sind. Daher wird die symbolische Kante mit einem Gaussfilter gefaltet und in das Gradientenbild projiziert. Die Schätzung minimiert den Abstand zwischen der Gaussfunktion der projizierten Kante und dem Gradientenbild. Falls die Orientierungsparameter der Aufnahme bekannt sind, und  $\beta$  die unbekannt Parameter der Oberflächengeometrie, lässt sich die bedingte Wahrscheinlichkeit als

$$p(\mathbf{g}|s) \propto \exp\left\{-\frac{1}{2}(\mathbf{g} - \mathbf{f}_g(\beta))^t \Sigma_g^{-1}(\mathbf{g} - \mathbf{f}_g(\beta))\right\}, \tag{3.1.2}$$

schreiben, wenn  $\mathbf{g}$  ein Gradientenvektor und  $\mathbf{f}_g$  die notwendige Projektionsfunktion der Kante in das Gradientenbild ist. Ein Verfahren zur Beobachtung von Kanten im Bild gibt LÖCHERBACH 1996 an.

<sup>5</sup>Symbolische Matchingverfahren sind für die Zuordnung nutzbar (s. u. a. VOSSELMAN 1992 und FUCHS *et al.* 1994)




Abbildung 3.9: Generelles Konzept der Gebäudeinterpretation: Aus einer Näherungsrepräsentation wird ein polymorpher Graph abgeleitet. Unter Verwendung unterschiedlicher Datenquellen und statistischen Wissens wird ein polymorphes Zufallsfeld generiert. Die Realisierung des Feldes wird optimiert.

- **Für beobachtete Punkte im Bild:**

$$p(\boldsymbol{\gamma}|s) \propto \exp\left\{-\frac{1}{2}(\boldsymbol{\gamma} - \mathbf{f}_{\boldsymbol{\gamma}}(\boldsymbol{\beta}))^t \boldsymbol{\Sigma}_{\boldsymbol{\gamma}}^{-1}(\boldsymbol{\gamma} - \mathbf{f}_{\boldsymbol{\gamma}}(\boldsymbol{\beta}))\right\}, \quad (3.1.3)$$

wenn  $\boldsymbol{\gamma}$  der Vektor ist, der den Punkt im Bild oder Gradientenbild beschreibt (s. FUCHS 1998).

- **Für beobachtete Höhen (z. B. aus Laserscannermessungen):**

$$p(\mathbf{h}|s) \propto \exp\left\{-\frac{1}{2}(\mathbf{h} - \mathbf{f}_{\mathbf{h}}(\boldsymbol{\beta}))^t \boldsymbol{\Sigma}_{\mathbf{h}}^{-1}(\mathbf{h} - \mathbf{f}_{\mathbf{h}}(\boldsymbol{\beta}))\right\}, \quad (3.1.4)$$

Vereinfachungen ergeben sich, wenn angenommen wird, dass die Höhen unter einer Orthogonalprojektion bestimmt wurden.

Diese Liste lässt sich durch weitere Datenquellen beliebig erweitern. Alle Datenquellen haben einen Einfluss auf die Klassifikation. Als weitere Information werden im nächsten Abschnitt Wahrscheinlichkeiten für Nachbarschaftsstrukturen eingeführt.

Die Verteilungen sind als statistische Filter interpretierbar, die Beobachtungen in Wahrscheinlichkeiten über Aussagen (Klassifikationen) übertragen. Es wird jedoch keine Entscheidung über die Interpretation getroffen, sondern die möglichen Aussagen werden zunächst nur mit Wahrscheinlichkeiten belegt.

## 3.2 Strategie des Verfahrens

Das Lösungsverfahren der Interpretations- und Rekonstruktionsaufgabe basiert auf einem gekoppelten Markoff-Zufallsfeld (Abs. 2.2.4), das das Likelihood- und das Nachbarschaftswissen kombiniert. Es wird auf der polymorphen Polyederoberfläche formuliert, indem jedem Punkt, jeder Kante und jeder Fläche eine Zufallsvariable zugeordnet wird. Auf die Definition der Klassen wurde in Abschnitt 3.1 eingegangen.

Die Struktur des dem verkoppelten Markoff-Zufallsfeldes zugrundeliegenden Graphens ist der polymorphe Polyeder, der aus einer auf der Topologie basierenden Näherungsrepräsentation generiert wird (s. Abb. 3.9). Knoten, Kanten und Dreiecke werden zu Knoten des verkoppelten Markoff-Zufallsfeldes. Alle drei Typen von Knoten des Zufallsfeldes werden in Hinblick auf ihre semantische Bedeutung bewertet.

Formal ergibt sich die folgende Beschreibung des Prozesses:

1. Eine topologische Näherungspolyederoberfläche ist für die Oberfläche  $S$  mit Geometrie und semantischer Belegung bekannt.  $T_0$  sei die topologische Repräsentation,  $K_0$  die a priori Klassifikation,  $G_0$  die Näherungsgeometrie und  $R_0$  eine Näherungsrepräsentation der Radiometrie.

$$S(T_0, K_0, G_0, R_0) \quad (3.2.1)$$

2. Die Oberfläche wird unter Verwendung der Gebäudemodelle (Nachbarschaften) erneut klassifiziert (s. Abs. 3.3).

$$S(T_{i+1}, K_{i+1}, G_i, R_i), i \in \{1, \dots\} \quad (3.2.2)$$

$i$  sei ein Zähler der Iterationen.

3. Die Oberfläche wird geometrisch korrigiert (s. Abs. 3.4).

$$S(T_{i+1}, K_{i+1}, G_{i+1}, R_{i+1}) \quad (3.2.3)$$

4. Sind die Korrekturen der Geometrie und der Radiometrie oberhalb eines Schwellwerts, wird mit Schritt 2 fortgefahren.

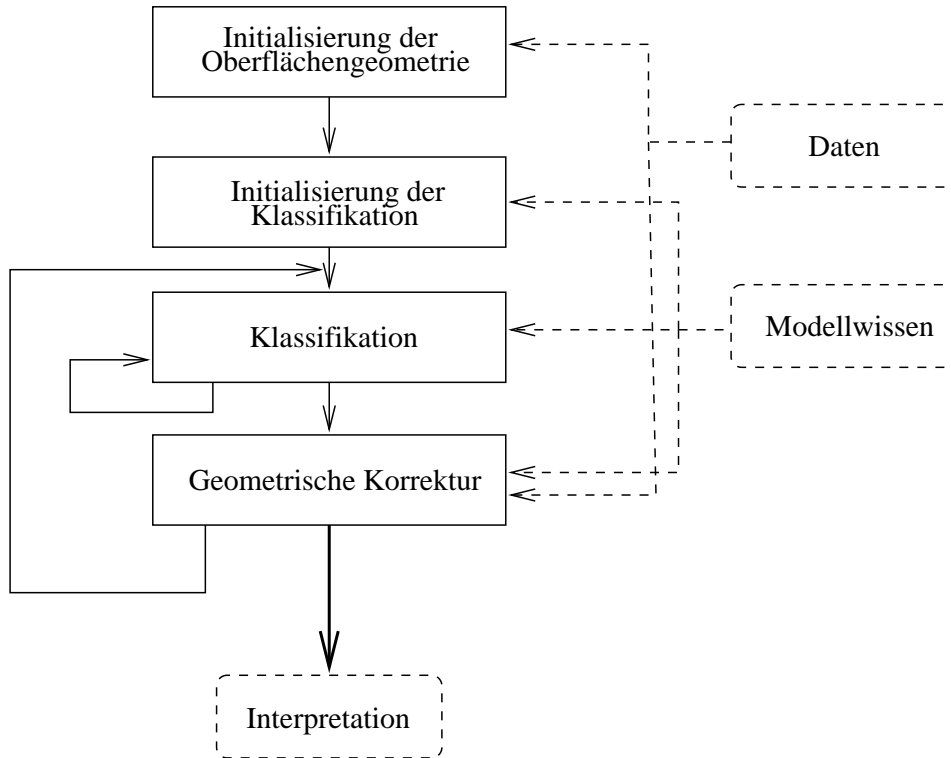


Abbildung 3.10: Überblick über den Auswerteprozess.

5. Ende.

Klassifikation und Rekonstruktion laufen also iterativ ab.

Für den verallgemeinerten Ansatz im Abschnitt 4 wird die Radiometrie nicht betrachtet und die Topologie als fest angenommen.

### 3.3 Das Klassifikationsproblem

Das Ziel des Klassifikationsschrittes ist die Belegung aller Zufallsvariablen (Zellen) mit einer möglichst konsistenten Klassifikation unter Verwendung der Daten und des Modellwissens.

Auf der polymorphen Polyederoberfläche wird ein verkoppeltes Markoff-Zufallsfeld definiert, indem sowohl für jeden Punkt, als auch jede Kante und jede Fläche jeweils ein Markoff-Zufallsfeld definiert wird und feldübergreifende Nachbarschaften eingeführt werden. Es werden daher die drei Typen von Zufallsvariablen  $S_P, S_E, S_F$ , die in den Mengen  $\mathcal{S}_P, \mathcal{S}_E, \mathcal{S}_F$  zusammengefasst sind, definiert. Die Zufallsvariablen werden in der Menge  $\mathcal{S}$  zusammengefasst.

$$\mathcal{S} = \mathcal{S}_P \cup \mathcal{S}_E \cup \mathcal{S}_F = \{S_P, S_E, S_F\} \quad (3.3.1)$$

Wenn  $\mathcal{M}_1$  und  $\mathcal{M}_2$  beliebige Elemente aus  $\mathcal{S}$  sind, gilt für alle Kombinationen von  $\mathcal{M}_1$  und  $\mathcal{M}_2$

$$\mathcal{M}_1 \cap \mathcal{M}_2 = \emptyset \quad \text{mit} \quad \mathcal{M}_1, \mathcal{M}_2 \in \{S_P, S_E, S_F\} \quad \text{und} \quad \mathcal{M}_1 \neq \mathcal{M}_2 \quad (3.3.2)$$

Für die Knoten  $s \in \mathcal{S}$  werden die Nachbarschaften entsprechend der topologischen Gebäudemodelle aus Abschnitt 3.1 definiert.

**Definition 3.3.1 (Polymorphes Markoff-Zufallsfeld)** *Ein Markoff-Zufallsfeld, das auf einer polymorphen Polyederoberfläche definiert ist, wird als Polymorphes Markoff-Zufallsfeld bezeichnet.*



Zur Modellierung der lokalen Abhängigkeiten werden die Klassifikationsergebnisse der Zufallsvariablen in der Nachbarschaft der betrachteten Zufallsvariable  $s$  als Vorwissen eingeführt. Nach Gleichung 2.2.5 gilt:

$$P(s|\partial s, \mathbf{y}) \propto P(\mathbf{y}|s, \partial s)P(s|\partial s) \quad (3.3.3)$$

Zur Interpretation der Oberfläche müssen die bedingten Wahrscheinlichkeiten  $P(s|\partial s)$  bekannt sein. Diese können aus empirischen Untersuchungen abgeleitet werden (s. Abs. 3.1.4). Für die Likelihood-Funktion  $P(\mathbf{y}|s, \partial s)$  wird angenommen, dass sie als Normalverteilung (s. a. Abs. 3.1.5) beschreibbar ist. Nach KOCH 1990, S. 63 lässt sich dann

$$P(\mathbf{y}|s, \partial s) \propto \exp\left\{-\frac{1}{2}(\mathbf{y} - \mathbf{X}_{s, \partial s} \boldsymbol{\beta}_{s, \partial s})^t \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \mathbf{X}_{s, \partial s} \boldsymbol{\beta}_{s, \partial s})\right\} \quad (3.3.4)$$

schreiben. Die  $\boldsymbol{\beta}_{s, \partial s}$  sind Erwartungswerte für die Parameter der Oberfläche. Bei einer geometrischen Repräsentation der Oberfläche durch Ebenen können dies die Parameter der angrenzenden Ebenen oder auch nur Zenitwinkel sein.  $\mathbf{X}_{s, \partial s}$  sind die Koeffizientenmatrizen der linearisierten Beobachtungsgleichungen.

Zur Reduktion des Rechenaufwandes wird diese Verteilung für die Klassifikation aufgrund von Beobachtungen  $\bar{\mathbf{y}}$  von Knoten der Näherungsoberfläche und nicht den ursprünglichen Sensordaten bestimmt werden.

Die bedingte Verteilung, die den Bezug zu den einzelnen Datensätzen enthält, kann als

$$P(\bar{\mathbf{y}}|s, \partial s) = P(\bar{\mathbf{y}}_1, \dots, \bar{\mathbf{y}}_d | s, \partial s) \quad (3.3.5)$$

geschrieben werden, wenn der Gesamtbeobachtungsvektor  $\bar{\mathbf{Y}}$  in die einzelnen Beobachtungsvektoren  $\bar{\mathbf{y}}_i$  aufgebrochen wird. Bei Unabhängigkeit der einzelnen Beobachtungsvektoren  $\bar{\mathbf{y}}_i$  mit Kenntnis der Klassifikationen  $s$  und  $\partial s$  kann die Gesamtverteilung als das Produkt der Einzelverteilungen geschrieben werden:

$$P(\bar{\mathbf{y}}_1, \dots, \bar{\mathbf{y}}_d | s, \partial s) = \prod_{i=1}^d P(\bar{\mathbf{y}}_i | s, \partial s) \quad (3.3.6)$$

oder

$$P(\bar{\mathbf{y}}_1, \dots, \bar{\mathbf{y}}_d | s, \partial s) = \prod_{i=1}^d \exp\left\{-\frac{1}{2}(\bar{\mathbf{y}}_i - \mathbf{X}_i \boldsymbol{\beta}_{i, s, \partial s})^t \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{y}}_i - \mathbf{X}_i \boldsymbol{\beta}_{i, s, \partial s})\right\} \quad (3.3.7)$$

$$= \exp\left\{-\frac{1}{2} \sum_{i=1}^d (\bar{\mathbf{y}}_i - \mathbf{X}_i \boldsymbol{\beta}_{i, s, \partial s})^t \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{y}}_i - \mathbf{X}_i \boldsymbol{\beta}_{i, s, \partial s})\right\} \quad (3.3.8)$$

### 3.4 Das Rekonstruktionsproblem

Ziel des Rekonstruktionsprozesses ist es, eine Beschreibung des Gebäudes zu erhalten, die einen Konsens zwischen den Daten und dem Modell erreicht. Dazu bedarf es der Auswahl von Daten und der Abwägung zwischen den Daten und dem Modell, da sowohl die Daten als auch die Klassifikation des Markoff-Zufallsfeldes fehlerhaft sein kann.

Zu den im Abschnitt 3.1 beschriebenen semantischen Modellen sind Ausprägungen in den unterschiedlichen Beobachtungstypen assoziiert<sup>6</sup>. Diese werden den Daten aufgeprägt, wenn sie von den Daten gestützt werden. Zusätzliche Freiheitsgrade werden aus den Abhängigkeiten innerhalb der Polyederoberfläche oder durch die Daten aufgelöst. Beispiele für zu schätzende Ausprägungen sind

- die lokale geometrische Struktur des Gebäudes mit angenommen Regelmäßigkeiten wie Rechtwinkeligkeit oder Symmetrie (BRUNN UND WEIDNER 1998),

<sup>6</sup>LANG 1999 hat dies für geometrische Modelle formuliert.

- die Farbverteilung innerhalb des interpretierten Teilobjektes und
- die Texturparameter einer Polyederfläche.

Weitere Beobachtungstypen erfordern weitere Modelle für Ausprägungen in den Daten.

Die Schätzung der Modelle erfolgt mit robusten Kleinste-Quadrate-Schätzern (s. Abs. 2.5).

### 3.5 Klassifikation der Gebäudetypen

Für jeden möglichen Gebäudetyp (Flachdachhaus, Giebeldachhaus, Walmdachhaus, ...) wird ein Modell definiert, für das dann ein Zufallsfeld berechnet wird. Die Modelle unterscheiden sich nur im statistischen Gebäudewissen, da die Häufigkeiten von Klassenkombination in den Nachbarschaften der Zellen variieren. Das Likelihoodwissen kann unabhängig vom Gebäudetyp beschrieben werden, da die Bedeutung der Gebäudeteile in der Regel nicht widersprüchlich sind. Zum Beispiel wird eine Gebäudewand immer näherungsweise senkrecht und eine Firstlinie immer als Schnittlinie zweier Dachflächen modelliert. Dachflächen sind dann jedoch so zu modellieren, daß sowohl horizontale als auch schräge Dachflächen möglich sind.

Für jeden Gebäudetyp wird die resultierende Gesamtwahrscheinlichkeit des MRFs bestimmt. Die Nachbarschaften sind in Abschnitt 3.1.3 so ausgewählt, dass Gleichung 2.2.19 gilt. Es wird der Typ von Gebäude ausgewählt, der die größte Gesamtwahrscheinlichkeit hat.

## Kapitel 4

# Gebäudeextraktion aus Laserdaten

In diesem Kapitel soll das Rekonstruktions- und Interpretationsmodell auf die konkrete Anwendung für die Analyse von Laserdaten angewandt werden. Die folgenden Spezialisierungen werden am in Abschnitt 3 beschriebenen Modell vorgenommen:

- Zunächst werden ausschließlich Flach- und Walmdachhäuser modelliert.
- Es wird eine triangulierte Oberfläche angenommen. Diese Entscheidung ist eng verknüpft mit der vorhandenen Vorverarbeitung, die eine triangulierte Oberfläche liefert. Die CW-Komplexe werden also für den Interpretationschritt auf Simpliziale Komplexe (s. Abs. 2.1.2) spezialisiert.
- Als Datenquelle werden rasterbasierte Digitale Oberflächenmodelle und aus diesen abgeleitete Triangulationen verwandt, die von Laserscannermessungen abstammen.
- Die semantische Modellierung wird auf eine geometrische Beschreibungsebene verallgemeinert<sup>1</sup>.

Für die statistische Bayes-Interpretation muss ein Beobachtungsmodell und a priori Wissen vorliegen. In den folgenden Abschnitten werden diese für Entfernungsdaten und die beiden erwähnten Gebäudetypen eingeführt. Die automatische Ableitung der Modellparameter wird ebenfalls erläutert. Die darauf folgenden Abschnitte behandeln dann den Klassifikations- und den Rekonstruktionsschritt.

### 4.1 Modellbildung

Es werden in diesem Kapitel die Modellierungen für einfache Flachdachhäuser und Walmdachhäuser abgeleitet. Beide Gebäudetypen verwenden zur Klassifikation der Oberflächenelemente die gleichen Klassen. Oberflächen von Gebäuden bestehen in der hier gewählten Abstraktion aus den folgenden Bestandteilen:

- Punkte: Flächenpunkte (FP), Kantenpunkte (KP) und Eckpunkte (EP) (3 Klassen),
- Kanten: Flächenkanten (FK) und Bruchkanten (BK) (2 Klassen),
- Flächen: horizontale Flächen (H), schräge Flächen ( $O^2$ ) und vertikale Flächen (V) (3 Klassen)

---

<sup>1</sup>Die Änderung der Modellierung von der semantischen auf eine geometrische Betrachtungsweise läßt sich als *Verallgemeinerung* bezeichnen, da die semantische die spezifischere Modellierung der beiden Betrachtungen ist und die geometrische Modellierung Oberklassen zu den semantischen Klassen modelliert (s. BRUNN 2000B).

<sup>2</sup>O für engl. *oblique*

Flächenpunkte sind Punkte, die innerhalb von Gebäudeebenen liegen; Kantenpunkte sind Punkte, innerhalb von Begrenzungskanten von koplanaren Flächen und Eckpunkte, sind Punkte, in denen genau drei Bruchkanten zusammentreffen.

Flächenkanten sind Kanten der Triangulation, die innerhalb von koplanaren Flächen liegen; Bruchkanten markieren den Übergang zwischen zwei nicht koplanaren Flächen.

Jeder Simplex wird entsprechend Abschnitt 3.3 auf eine Zufallsvariable abgebildet und klassifiziert. Der Wertebereich der Zufallsvariablen  $\mathbf{s}$  wird mit  $\mathcal{L}$  bezeichnet, seine Elemente mit  $l_k, k \in \{1, \dots, 8\}$ .  $\mathcal{L}$  kann zerlegt werden in den Wertebereich der Punktknoten  $\mathcal{L}_V = \{FP, KP, EP\}$ , der Kantenknoten  $\mathcal{L}_K = \{FK, BK\}$  und der Dreiecksknoten  $\mathcal{L}_F = \{H, O, V\}$ . Durch das Markoff-Zufallsfeld sind Abhängigkeiten zwischen benachbarten Klassifikationen bekannt. Unter Berücksichtigung dieser Abhängigkeiten auf der Basis der Daten soll eine optimale Belegung des Zufallsfeldes bestimmt werden.

Analog zu Abschnitt 3.1.3 definieren wir die in Abb. 4.1 dargestellten Nachbarschaftsstrukturen.



Abbildung 4.1: Nachbarschaftsdefinition auf der triangulierten Polyederoberfläche. Diese Abbildung ist eine Spezialisierung der Abbildung 3.8.

- Punktnachbarschaft: Punkte sind zu den Kanten benachbart, deren konvexer Abschluss sie sind, und zu den anderen Endpunkten der Kanten.
- Kantennachbarschaft: Kanten sind zu ihrem Anfangs- und Endpunkt sowie zu den angrenzenden Dreiecken benachbart, sowie zu den anderen Begrenzungskanten der angrenzenden Dreiecke.
- Dreiecksnachbarschaft: Dreiecke sind zu den Kanten benachbart, die Teil ihrer konvexen Hülle sind.

Diese Nachbarschaften ergeben sich als Spezialisierungen der auf den CW-Komplexen definierten Nachbarschaften (s. Abs. 3.1.3).

Für die Nachbarschaftsrelationen wird eine Teilmenge von Nachbarschaftsordnungen ausgewählt. Die folgenden Nachbarschaften werden betrachtet:

- Für Punkte  $v$ : Nachbarschaft zu abgehenden Kanten und deren Endpunkte: Um mit der variablen Kardinalität der Punkte des Graphen umgehen zu können, wird die Anzahl der Bruchkantenklassifikationen ( $\#BK(v)$ ) und die Anzahl der Eckpunktklassifikation ( $\#EP(v)$ ) als Zufallsvariable betrachtet.

$$P_M(l_v | \#BK(v), \#EP(v)) \quad (4.1.1)$$

Die möglichen Realisierungen der Knoten werden mit  $l_v, v \in \mathcal{L}_V$  bezeichnet. Die Zufallsvariablen  $\#BK(v)$  und  $\#EP(v)$  können die Werte 0 bis  $\infty$  annehmen, wobei die maximale Anzahl durch die Kardinalität des Knotens im Graphen eingeschränkt ist. Tatsächlich treten an realen Gebäuden nur Knoten mit geringer Anzahl von abgehenden Bruchkanten oder sich anschließenden Eckpunkten auf. Daher werden beide Zufallsvariablen auf den Wertebereich 0 bis 4 beschränkt. Werden mehr Bruchkanten oder mehr Eckpunkte innerhalb der Nachbarschaft gefunden, wird die Anzahl auf 4 gesetzt.

Wir nehmen eine Zerlegbarkeit der bedingten Wahrscheinlichkeiten in Gleichung 4.1.1 an. Es gilt dann

$$P_M(l_v | \#BK(v), \#EP(v)) = P_M(l_v | \#BK(v)) P_M(l_v | \#EP(v)). \quad (4.1.2)$$

- Für Kanten  $e$ : Nachbarschaft zu den Endpunkten und den angrenzenden Dreiecken, wie auch zu den anderen beiden Kanten der angrenzenden Dreiecke. Für die Dreiecke und Punkte werden die Klassifikationspaare berücksichtigt; für die Punkte  $Qp = \{l_{p_1}, l_{p_2}\}$  mit  $\{l_{p_1}, l_{p_2}\} \in \mathcal{L}_F \times \mathcal{L}_F$  und für die Dreiecke  $Qf = (l_{f_1}, l_{f_2})$  mit  $(l_{f_1}, l_{f_2}) \in \mathcal{L}_P \times \mathcal{L}_P$ . Die Sortierung der Paare wird nicht berücksichtigt. Im Falle der angrenzenden Kanten wird die Anzahl der Bruchkantenklassifikation  $\#BK(e)$  berücksichtigt.

$$P_M(l_e | Qp, Qf, \#BK(e)) \quad (4.1.3)$$

Die möglichen Realisierungen der Kanten werden mit  $l_e, e \in \mathcal{L}_K$  bezeichnet. Es wird wiederum angenommen, dass die bedingte Wahrscheinlichkeitsverteilung zerlegt werden kann:

$$P_M(l_e | Qp, Qf, \#BK(e)) = P_M(l_e | Qp, Qf) P_M(l_e | \#BK(e)) \quad (4.1.4)$$

Es ergeben sich die folgenden Wertebereiche<sup>3</sup>:

- $Qp \in \{(EP, EP), (EP, KP), (EP, FP), (KP, KP), (KP, FP), (FP, FP)\}$
- $Qf \in \{(H, H), (H, O), (H, V), (V, V), (V, O), (O, O)\}$
- $\#BK(e) \in \{0, 1, 2, 3, 4\}$

Die Elemente der Wertebereiche von  $Qp$  und  $Qf$  werden in der angegebenen Reihenfolge durchnummeriert, da im Folgenden für den Aufbau der Matrizen der relativen Häufigkeiten und der bedingten Wahrscheinlichkeiten auf die Nummerierung der Elemente zurückgegriffen wird.

- Für Dreiecke  $f$ : Nachbarschaft zu den umschließenden Kanten. Hier wird nur die Anzahl der angrenzenden Bruchkanten  $\#BK(f) \in \{0, 1, 2, 3\}$  für die bedingte Verteilung berücksichtigt.

$$P_M(l_f | \#BK(f)) \quad (4.1.5)$$

Die möglichen Realisierungen der Dreiecke werden mit  $l_f, f \in \mathcal{L}_F$  bezeichnet.

In den Abb. 4.2 und 4.3 sind nochmals alle relativen Häufigkeiten und bedingten Wahrscheinlichkeiten des Gebäudemodells mit allen Realisierungen zusammengestellt. Die bedingten Wahrscheinlichkeiten müssen für jeden Gebäudetyp definiert werden. Der Index  $M$  markiert die unterschiedlichen Gebäudetypen. Realisiert worden sind in dieser Arbeit viereckige Flachdach- und Walmdachhäuser ( $M \in \{F, W\}$ ). In Abbildung 4.4 werden die repräsentative Oberflächenbeschreibung für ein Flachdachgebäude und in Abbildung 4.7 die repräsentative Oberflächenbeschreibung für ein Walmdachgebäude gezeigt. Das Lernverfahren (s. Abs. 3.1.4) liefert für die Gebäudetypen die in Abbildungen 4.5 und 4.6 angegebenen relativen Häufigkeiten  $H(l_v | \cdot)$  für Knoten,  $H(l_e | \cdot)$  für Kanten und  $H(l_f | \cdot)$  für Flächen. In den Abbildungen gibt der Index von  $H$  den Gebäudetyp an. Die relativen Häufigkeiten sind als Vektoren, Matrizen oder Tensoren entsprechend der Anzahl der Elemente im jeweiligen Bedingungsteil angegeben.  $H_F(l_e = BK | Qp = (EP, EP), Qf = (V, V)) = 4$  (1. Zeile, 4. Spalte) gibt die relative Häufigkeit einer Bruchkante eines Flachdachgebäudes an, wenn in der Nachbarschaft zwei vertikale Dreiecke und zwei Eckpunkte sind<sup>4</sup>

Da die Häufigkeiten nur aus der idealen Repräsentation der Gebäudetypen gelernt wurden, sind sehr viele Elemente der Häufigkeitsmatrizen und -vektoren 0. Die ideale Repräsentation

<sup>3</sup>Zur Verkürzung der Schreibweise wird im folgenden nicht mehr zwischen der Zufallsvariablen und der Belegung der Zufallsvariablen unterschieden. Daher wird die Angabe eines Wertebereiches für alle Belegungen einer Zufallsvariable  $s$  mit  $s \in \mathcal{S}$  möglich.

<sup>4</sup>Es handelt sich hier um die vier aufgehenden Ecken des Gebäudes.

$$H_M(l_v | \#BK(v)) = ((H_M(l_v = i | \#BK(v) = j))_{ij}) \quad (4.1.6a)$$

$$H_M(l_v | \#EP(v)) = ((H_M(l_v = i | \#EP(v) = j))_{ij}) \quad (4.1.6b)$$

$$H_M(l_e | Qp, Qf) = ((H_M(l_e = (BK, FK) | Qp = i, Qf = j))_{ij}) \quad (4.1.6c)$$

$$H_M(l_e | \#BK(e)) = ((H_M(l_e = (BK, FK) | \#BK(e) = i))_i) \quad (4.1.6d)$$

$$H_M(l_f | \#BK(f)) = ((H_M(l_f = i | \#BK(f) = j))_{ij}) \quad (4.1.6e)$$

Abbildung 4.2: Satz von Häufigkeiten, die für jedes Gebäudemodell aus den repräsentativen Datensätzen abgeleitet werden. Für die Wertebereiche der Belegungen der Zufallsvariablen siehe die Gleichungen 4.1.1 bis 4.1.5.

$$P_M(l_v | \#BK(v)) = ((P_M(l_v = i | \#BK(v) = j))_{ij}) \quad (4.1.7a)$$

$$P_M(l_v | \#EP(v)) = ((P_M(l_v = i | \#EP(v) = j))_{ij}) \quad (4.1.7b)$$

$$P_M(l_e | Qp, Qf) = ((P_M(l_e = (BK, FK) | Qp = i, Qf = j))_{ij}) \quad (4.1.7c)$$

$$P_M(l_e | \#BK(e)) = ((P_M(l_e = (BK, FK) | \#BK(e) = i))_i) \quad (4.1.7d)$$

$$P_M(l_f | \#BK(f)) = ((P_M(l_f = i | \#BK(f) = j))_{ij}) \quad (4.1.7e)$$

Abbildung 4.3: Satz von bedingten Wahrscheinlichkeiten, die für jedes Gebäudemodell definiert oder gelernt werden müssen. Für die Wertebereiche der Belegungen der Zufallsvariablen siehe die Gleichungen 4.1.1 bis 4.1.5.




Abbildung 4.4: Ausgewählte Repräsentation einer Oberfläche eines Flachdachhauses.

enthält keine zusätzliche Information über diese Fälle. Zum Erlernen dieser Häufigkeiten müsste das Lernverfahren auf einen Satz von Klassifikationen angewandt werden, die auch Fehler enthalten. Diese Daten müssten interaktiv klassifiziert und dann ausgewertet werden.

Aus den relativen Häufigkeiten werden bedingten Wahrscheinlichkeiten durch Normierung abgeleitet. Diese sind in den Abbildungen 4.8 und 4.9 angegeben. Um der Unwissenheit des Lernverfahrens über Konstellationen, die real existieren, die aber in dem ausgewählten Datensatz nicht vorkommen, gerecht zu werden, werden die assoziierten Häufigkeiten auf einen kleine Wert  $\epsilon = 1e - 6$  gesetzt. Damit ist dann für alle bedingten Wahrscheinlichkeitsverteilungen die Normierung möglich.

$$\left( (H_F(l_v = i \mid \#BK(v) = j))_{ij} \right) \propto \begin{pmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 16 & 0 & 0 \\ 0 & 0 & 0 & 8 & 0 \end{pmatrix} \quad (4.1.8a)$$

$$\left( (H_F(l_v = i \mid \#EP(v) = j))_{ij} \right) \propto \begin{pmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 8 & 8 & 0 & 0 \\ 0 & 8 & 0 & 0 & 0 \end{pmatrix} \quad (4.1.8b)$$

$$\left( (H_F(l_e = (BK, FK) \mid Qp = i, Qf = j))_{ij} \right) \quad (4.1.8c)$$

$$\propto \begin{pmatrix} (0,0) & (0,0) & (0,0) & (4,0) & (0,0) & (0,0) \\ (0,0) & (0,0) & (16,0) & (0,8) & (0,0) & (0,0) \\ (0,8) & (0,0) & (0,0) & (0,0) & (0,0) & (0,0) \\ (0,9) & (0,0) & (8,0) & (0,12) & (0,0) & (0,0) \\ (0,12) & (0,0) & (0,0) & (0,0) & (0,0) & (0,0) \\ (0,0) & (0,0) & (0,0) & (0,0) & (0,0) & (0,0) \end{pmatrix}$$

$$\left( (H_F(l_e = (BK, FK) \mid \#BK(e) = i))_i \right) \quad (4.1.8d)$$

$$\propto ( (8,0) \quad (16,20) \quad (4,19) \quad (0,10) \quad (0,0) )$$

$$\left( (H_F(l_f = i \mid \#BK(f) = j))_{ij} \right) \propto \begin{pmatrix} 10 & 16 & 4 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 16 & 8 & 0 \end{pmatrix} \quad (4.1.8e)$$

Abbildung 4.5: Modellhäufigkeiten für ein viereckiges Flachdachgebäude.

## 4.2 Die Näherungsoberfläche

Als Datengrundlage zur Generierung einer geometrischen Näherungsoberfläche dienen aus Laserdaten abgeleitete digitale Höhenmodelle, die die Objektoberfläche in einer 2.5 D Repräsentation beschreiben.

$$h(x_i, y_j) \quad (4.2.1)$$

Wie in Abs. 1.3.2.2 beschrieben, werden unterschiedliche Techniken zur Lasermessung und zur Ableitung der DOM aus Laserdaten eingesetzt. Um eine Modellierung der unterschiedlichen Techniken der Laserbefliegung zu umgehen, wird das in dem genannten Abschnitt beschriebene vereinfachte Laserscannermodell verwandt.

Die Erzeugung einer näherungsweise Oberflächenbeschreibung erfordert den Übergang einer 2.5 D Oberflächenrepräsentation in eine 3D Darstellung. Für diesen Übergang muß bereits Information über Gebäude dem Verfahren zugeführt werden. Der Prozess gliedert sich in zwei wesentliche Schritte:

1. die Selektion von Strukturelementen der Oberfläche aus den Laserdaten und

$$((H_W(l_v = i \mid \#BK(v) = j))_{ij}) \propto \begin{pmatrix} 0 & 0 & 3 & 10 & 2 \\ 0 & 1 & 12 & 1 & 0 \\ 7 & 1 & 0 & 1 & 0 \end{pmatrix} \quad (4.1.9a)$$

$$((H_W(l_v = i \mid \#EP(v) = j))_{ij}) \propto \begin{pmatrix} 1 & 4 & 3 & 1 & 0 \\ 0 & 0 & 5 & 8 & 1 \\ 2 & 5 & 5 & 3 & 0 \end{pmatrix} \quad (4.1.9b)$$

$$((H_W(l_e = (BK, FK) \mid Qp = i, Qf = j))_{ij}) \quad (4.1.9c)$$

$$\propto \begin{pmatrix} (0,0) & (0,0) & (0,0) & (4,0) & (6,0) & (2,0) \\ (0,0) & (0,0) & (4,0) & (0,16) & (10,2) & (4,2) \\ (0,4) & (0,2) & (0,0) & (0,0) & (0,4) & (2,9) \\ (0,0) & (0,0) & (2,0) & (0,4) & (2,0) & (0,2) \\ (0,6) & (0,0) & (0,0) & (0,1) & (0,4) & (2,15) \\ (0,0) & (0,0) & (0,0) & (0,2) & (0,5) & (0,3) \end{pmatrix}$$

$$((H_W(l_e = i \mid \#BK(e))_i) \quad (4.1.9d)$$

$$\propto ( (8,17) \quad (17,32) \quad (10,23) \quad (3,8) \quad (0,1) )$$

$$((H_W(l_f = i \mid \#BK(f) = j))_{ij}) \propto \begin{pmatrix} 5 & 6 & 0 & 0 \\ 7 & 16 & 8 & 0 \\ 14 & 17 & 6 & 3 \end{pmatrix} \quad (4.1.9e)$$

Abbildung 4.6: Modellhäufigkeiten für ein Walmdachgebäude.




Abbildung 4.7: Ausgewählte Repräsentation der Oberfläche eines Walmdachhauses.



$$((P_F(l_v = i \mid \#BK(v) = j))_{ij}) \propto \begin{pmatrix} 0.2 & 0.2 & 0.2 & 0.2 & 0.2 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{pmatrix} \quad (4.1.10a)$$

$$((P_F(l_v = i \mid \#EP(v) = j))_{ij}) \propto \begin{pmatrix} 0.2 & 0.2 & 0.2 & 0.2 & 0.2 \\ 0 & 0.5 & 0.5 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{pmatrix} \quad (4.1.10b)$$

$$((P_F(l_e = (BK, FK) \mid Qp = i, Qf = j))_{ij}) \quad (4.1.10c)$$

$$\propto \begin{pmatrix} (0,0) & (0,0) & (0,0) & (1,0) & (0,0) & (0,0) \\ (0,0) & (0,0) & (1,0) & (0,1) & (0,0) & (0,0) \\ (0,1) & (0,0) & (0,0) & (0,0) & (0,0) & (0,0) \\ (0,1) & (0,0) & (1,0) & (0,1) & (0,0) & (0,0) \\ (0,1) & (0,0) & (0,0) & (0,0) & (0,0) & (0,0) \\ (0,0) & (0,0) & (0,0) & (0,0) & (0,0) & (0,0) \end{pmatrix}$$

$$((P_F(l_e = (BK, FK) \mid \#BK(e) = i))_i) \quad (4.1.10d)$$

$$\propto ( (0.29, 0) \quad (0.57, 0.51) \quad (0.14, 0.49) \quad (0, 0.25) \quad (0, 0) )$$

$$((P_F(l_f = i \mid \#BK(f) = j))_{ij}) \propto \begin{pmatrix} 0.33 & 0.53 & 0.13 & 0 \\ 0.25 & 0.25 & 0.25 & 0.25 \\ 0 & 0.66 & 0.33 & 0 \end{pmatrix} \quad (4.1.10e)$$

Abbildung 4.8: Modellwahrscheinlichkeiten für ein viereckiges Flachdachgebäude.

$$((P_W(l_v = i \mid \#BK(v) = j))_{ij}) \propto \begin{pmatrix} 0 & 0 & 0.2 & 0.66 & 0.13 \\ 0 & 0.07 & 0.86 & 0.07 & 0 \\ 0.78 & 0.11 & 0 & 0.11 & 0 \end{pmatrix} \quad (4.1.11a)$$

$$((P_W(l_v = i \mid \#EP(v) = j))_{ij}) \propto \begin{pmatrix} 0.11 & 0.44 & 0.33 & 0.11 & 0 \\ 0 & 0 & 0.36 & 0.57 & 0.071 \\ 0.13 & 0.33 & 0.33 & 0.2 & 0 \end{pmatrix} \quad (4.1.11b)$$

$$((P_W(l_e = (BK, FK) \mid Qp = i, Qf = j))_{ij}) \quad (4.1.11c)$$

$$\propto \begin{pmatrix} (0,0) & (0,0) & (0,0) & (1,0) & (1,0) & (1,0) \\ (0,0) & (0,0) & (1,0) & (0,1) & (0.83, 0.17) & (0.67, 0.33) \\ (0,1) & (0,1) & (0,0) & (0,0) & (0,1) & (0.18, 0.82) \\ (0,0) & (0,0) & (1,0) & (0,1) & (1,0) & (0,1) \\ (0,1) & (0,0) & (0,0) & (0,1) & (0,1) & (0.12, 0.88) \\ (0,0) & (0,0) & (0,0) & (0,1) & (0,1) & (0,1) \end{pmatrix}$$

$$((P_W(l_e = (BK, FK) \mid \#BK(e) = i))_i) \quad (4.1.11d)$$

$$\propto ( (0.21, 0.23) \quad (0.45, 0.43) \quad (0.26, 0.31) \quad (0.08, 0.11) \quad (0, 0.01) )$$

$$((P_W(l_f = i \mid \#BK(f) = j))_{ij}) \propto \begin{pmatrix} 0.45 & 0.55 & 0 & 0 \\ 0.22 & 0.52 & 0.26 & 0 \\ 0.35 & 0.43 & 0.15 & 0.08 \end{pmatrix} \quad (4.1.11e)$$

Abbildung 4.9: Modellwahrscheinlichkeiten für ein Walmdachgebäude.

2. die Generierung einer 3D Repräsentation aus den Strukturelementen.

Durch die Selektion von Strukturelementen der Oberfläche wird eine Ausdünnung der zu bearbeitenden Daten erreicht.

Eine Approximation der Oberfläche ist aus verschiedenen Gründen sinnvoll und notwendig:

- Durch die Ausdünnung verringert sich die Berechnungsdauer der folgenden Rekonstruktion.
- Durch die Merkmalsextraktion können Bereiche mit geringer Informationsdichte von Bereichen mit großer Informationsdichte unterschieden werden. Die nachfolgende statistische Auswertung kann auf die definierten Nachbarschaftsstrukturen aufsetzen. In Bereichen geringer Informationsdichte kann stärker approximiert werden.
- Durch die Transformation der Rasterdaten in eine Dreiecksrepräsentation können die Punkte frei (kontinuierlich) im Raum verschoben werden. Bei der nachfolgenden Rekonstruktion können so die Gebäudeelemente auf Subpixelgenauigkeit bestimmt werden.

In dieser Arbeit wurden Laserdaten verwandt, die auf ein Raster interpoliert wurden. Prinzipiell lässt sich die Extraktion von Merkmalen auch auf unregelmässig verteilten vermaschten Punkte durchführen. Unterschiede bestehen im Einzelfall im Prozentsatz der Ausreisser (bei nicht bereinigten Daten), der Varianz der Beobachtungen und in der Diskretisierung der Ausdünnungsverfahren. Für Rasterlaserdaten lässt sich Bildverarbeitungssoftware verwenden, so dass hier auf bekannte Techniken zurückgegriffen werden konnte.

#### 4.2.1 Extraktion von Strukturelementen der Oberfläche

Durch die Extraktion von Strukturelementen der Oberfläche soll die Basis für eine 3D Darstellung generiert werden. Senkrechte Wände und aufgehende Gebäudeecken erscheinen im DOM als 2D Strukturen. Diese müssen aufgespaltet werden, um eine Unterscheidung zwischen den unterschiedlichen Strukturebenen am 3D Gebäude zu erreichen. Dazu werden die Strukturelemente durch den nachfolgenden Prozess in ihrer Lage verschoben. Die reale Projektion der Strukturelemente in das Gebäude liegt in der Mitte der Projektion der beiden aufgespalteten extrahierten Strukturelemente.

Die Extraktion von Strukturelementen der Oberfläche besteht aus den folgenden Schritten<sup>5</sup>:

- Vergrößerung und Verkleinerung der Gebäude: Das DOM wird mittels morphologischer Operatoren dilatiert und erodiert. Durch die Erosion bzw. die Dilation werden die Gebäude in den Rasterlaserdaten vergrößert bzw. verkleinert. So wird eine Duplizierung der Trauf-/Grundrissgebäudepunkte im DOM für die 3D Beschreibung erreicht. Ebenso werden die Trauf- und Grundrisskanten verdoppelt.

Die morphologischen Operationen implizieren gleichzeitig eine Glättung des Signals. Die Filterweite muß so gewählt werden, dass trotz der Glättung keine oder nur geringe Auswirkungen auf die Detektierbarkeit der wesentlichen Beschreibungselemente des Gebäudes zu erwarten sind.

Diese Technik erreicht nur eine Verdoppelung der Punkte an vertikalen Wänden. Nicht ausreichend ist dieses Vorgehen, wenn eine Verdoppelung der Punkte nicht genügt. Verbindungspunkte zwischen zwei nicht koplanaren horizontalen Dachflächen erfordern zum Beispiel bereits eine Verdreifachung eines 2.5 D Punktes.

Zur Lösung dieses Problems bedarf es eine genaueren lokalen Analyse des DOMs in der Nachbarschaft extrahierter Punkte. Mit einer angenommen Varianz der Beobachtungen ist ein Clusterverfahren zur Bestimmung der Anzahl der Häufungspunkte möglich. Die Erfahrungen mit Laserdaten haben gezeigt, dass die Auflösung der Laserdaten nicht ausreicht.

---

<sup>5</sup>Zur Dokumentation der einzelnen Schritte anhand eines Beispiels wird hier auf Kapitel 5 verwiesen.

- Berechnung der Gradientenbilder<sup>6</sup>: Sowohl für das erodierte als auch das dilatierte DOM wird das Gradientenbild berechnet. Die Gradienten der Digitalen Oberflächenmodelle werden mittels  $3 \times 3$  Sobeloperatoren bestimmt. Andere Filterweiten sind bei einer anderen Datenqualität notwendig. Die glättende Eigenschaft muß bei der Wahl der Filterweite berücksichtigt werden.
- Extraktion von Strukturelementen: Aus den zweikanaligen Gradientenbildern werden Punkte und Kanten mittels einer Merkmalsextraktion extrahiert. Zur Extraktion der Strukturelemente der Gradientenbilder wird die Merkmalsextraktion (FEX) von FUCHS 1998 verwandt.

Damit liegen zwei in der Regel unvollständige symbolische 2D Beschreibungen des Gebäudes vor. Im nächsten Abschnitt werden beide Beschreibungen zu einem 3D Gebäude fusioniert.

### 4.2.2 Generierung einer 3D Gebäudebeschreibung

Aus den beiden symbolischen DOM-Beschreibungen soll nun eine gemeinsame 3D Gebäudebeschreibung abgeleitet werden. Dies geschieht in drei Schritte:

- Die beiden symbolischen DOM Beschreibungen werden überlagert. Extrahierte Punkte und Kanten werden überlagert. Traufkanten und Grundrisskanten werden zu näherungsweise parallelen Kanten in der gemeinsamen Beschreibung. Abhängig von den morphologischen Filterbreiten und der Dachneigung sind korrespondierende Firstlinien in beiden Beschreibungen nahezu lagegleich oder brechen in drei Kanten auf.

Daher werden für die Fusion die folgenden Regeln definiert:

- Schneiden sich zwei Kanten und sind sie nicht nahezu identisch, berechne den Schnittpunkt und führe den Schnittpunkt als weiteren 3D Punkt ein. Schneiden sich mehrere Kanten, wird die Regel rekursiv verwandt.
- Ist der Schnitt zwei Kanten lagegleich, unterscheiden sie sich nur in der Länge, wähle die kürzere aus.
- Die symbolischen Beschreibungen sind 2D Beschreibungen, so dass zunächst den 2D Punkte Höhen zugeordnet werden. Sichere Höhen werden durch weitere morphologische Operationen auf dem erodierten und dilatierten DOM erreicht. Dazu wird das erodierte DOM dilatiert, und das dilatierte DOM erodiert. Um eine robuste Höhenauswahl zu erreichen, wird die Höhe aus dem jeweils zunächst invers morphologisch gefilterten DOM abgegriffen. Punkte der symbolischen Beschreibung des dilatierten (erodierten) DOMs werden mit einer Höhe aus dem erodierten (dilatierten) versehen. So ist sichergestellt, dass für Grundrisspunkte, die in der dilatierten symbolischen Beschreibung repräsentiert werden, Umgebungshöhen und für Traufkantenpunkte, die in der erodierten symbolischen Beschreibung repräsentiert werden, grössere Höhen gewählt werden.

Für Schnittpunkte der Überlagerung wird die Höhe aus dem originalen DOM abgegriffen.

Als zusätzliche Punkte wird der 3D Gebäudebeschreibung ein Rand bestehend aus acht Umgebungspunkten hinzugeführt, um einen Abschluß der 3D Beschreibung sicher zu stellen, der Umgebungspunkte beinhaltet. Die Betrachtung des Randes wird so vereinfacht.

- Die gemeinsame symbolische Objektbeschreibung wird nun trianguliert. In die Triangulation gehen als Knoten die extrahierten Merkmalspunkte und die Kantenendpunkte ein. Kantenverbindungen werden als Restriktionen der Triangulation eingeführt. Zur Generierung einer vollständigen Oberfläche wird die Delauney-Triangulation verwandt, um Dreiecke mit möglichst großem minimalen Innenwinkel zu erhalten.

<sup>6</sup>In den folgenden Schritten werde Bildverarbeitungsverfahren auf die DOM angewendet. Um die Erläuterungen zu vereinfachen, wird im Folgenden das DOM als ein Bild aufgefaßt.

Die Triangulation arbeitet rein geometrisch in 2D. Es wird also kein weiteres Gebäudewissen berücksichtigt. Wenn wesentliche Beschreibungselemente des Gebäudes, z. B. Traufkanten und Grundrisskanten fehlen, ist nicht eine im Sinne der Gebäudetopologie korrekte Verma-schung sichergestellt.

Für Teile der Näherungsoberfläche können die folgenden topologischen Fehler auftreten:

- Ein zusätzlicher Punkt innerhalb einer Fläche: die Punktselektion hat innerhalb einer Ober-fläche einen nicht relevanten Punkt entdeckt.
- Ein zusätzlicher Punkt innerhalb einer Kante: die Punktselektion hat innerhalb einer Bruch-kante eine nicht relevante Stützstelle selektiert.
- Ein Eckpunkt ist nicht detektiert worden, aber die 3 Bruchkantenpunkte in seiner Nähe: Das Dreieck ist mit einem weiteren Punkt in der Mitte zu ergänzen.
- Eine Kante zeigt in eine falsche Richtung, orthogonal zu einer sinnvollen Objektkante; ins-besondere für Bruchkanten kommt das häufig vor. Ein Flippen der Triangulationskante ist in diesem Fall notwendig.

Die Fehler in der Verkantung des Graphens werden bisher in dieser Arbeit durch interaktiven Edi-tieren gelöst. Zusätzliche oder nicht detektierte Punkte werden nicht korrigiert. Die Klassifikation muß mit diesen topologischen Fehlern umgehen.

Die ungenaue Lage der zur Beschreibung der Oberfläche relevanten Punkte wird hier nicht als Fehler sondern als Ungenauigkeit angesehen. Es wird die Parametrisierung nach Gleichung A.2.2 gewählt.

## 4.3 Klassifikation

In diesen Abschnitt wird der Klassifikationsschritt beschrieben. Nachdem der prinzipielle Lösungs-algorithmus beschrieben ist, wird auf die Teilschritte der Klassifikation eingegangen.

### 4.3.1 Lösungsalgorithmen des MRFs

Das zu lösende Klassifikationsproblem ist die Bestimmung des Maximums einer hochdimensionalen Wahrscheinlichkeitsfunktion. Die Dimension dieser Funktion ist die Summe der Punkt-, Knoten- und Dreiecksanzahlen. Das Aussehen der Wahrscheinlichkeitsfunktion ist nicht bekannt. Die ini-tiale Klassifikation kann aufgrund von Fehlern in der Generierung der Näherungsoberfläche stark von der optimalen Lösung abweichen.

Die Wahl des Lösungsalgorithmusses in dieser Arbeit ist durch zwei Ziele motiviert: Zum Einen soll die optimale Lösung für das Klassifikationsproblem gesucht werden. Zum anderen soll durch einen Vergleich der Lösungen von unterschiedlichen Lösungsansätzen die Optimierungsfunktion charakterisiert werden. Daher wurden zwei Lösungsalgorithmen implementiert:

- der ICM-Algorithmus als deterministisches Verfahren (s. Abs. 2.2.5.2) und
- eine Variante des Metropolis-Algorithmus als stochastisches Verfahren.

Beide Lösungsverfahren nutzen die gleiche Prior-Klassifikation.

Die Variante des Metropolis-Algorithmusses beinhaltet die folgenden Schritte:

1. Klassifikation aufgrund der Geometrie im Knoten, ohne Nachbarschaften mittels der Like-lihoodfunktion;
2. Zufälliger Zugriff auf die Elemente des Zufallsfeldes:
  - Zufällige Generierung einer neuen Klassifikation  $k_0$ ;

- Wenn eine Zufallszahl kleiner einem Schwellwert, dann wird die Klassifikation übernommen;

3. Fortfahren bei 2 bis die Anzahl der Klassifikationen  $n$ -Iterationen unter  $m$  Knoten bleibt.

Im Gegensatz zum allgemeinen Vorgehen, starten wir nicht mit einer zufälligen Klassifikation, sondern mit einer Likelihood-Schätzung. Die Absenkungsfunktion für  $n$  Anzahl der Iterationen des MRFs ist hier analog zu GEMAN UND GEMAN 1984 als

$$T = \frac{T_o}{\log(1 + I)} \quad (4.3.1)$$

definiert,  $I \in \{1, \dots\}$  bezeichnet die Nummerierung der Iteration des Klassifikationsschrittes. Der Zähler innerhalb des ersten Klassifikationsschritts des zweistufigen Verfahrens initialisiert und in jedem Iterationsschritt der Klassifikation um eins erhöht.

Mit der Auswahl der beiden Lösungsverfahren ist es möglich im Vergleich zu prüfen, ob die Annahmen über das Bewertungsproblem gerechtfertigt waren. Unterscheiden sich die Lösungen bei gegebener Näherungslösung nicht, kann von einer lokal hinreichend konvexen Wahrscheinlichkeitsfunktion ausgegangen werden. Differieren die beiden Lösungen, bestätigt sich die Annahme der Nicht-Konvexität. Für den Vergleich müssen die Initialisierungstemperatur und die verwandte Abkühlungsfunktion jedoch berücksichtigt werden.

### 4.3.2 Beobachtungen

Für die Likelihood-Funktionen sind Beobachtungen am Objekt notwendig. Da als Beobachtungen die Laserscannerdaten vorliegen, wären diese auch Daten für die Likelihood-Funktion verwendbar. Hier jedoch werden zur Reduktion der Komplexität der Beobachtungsselektion abgeleitete Beobachtungen herangezogen.

Zum Einen dienen die Normalenvektoren der Triangulationsdreiecke als Beobachtungen. Die Normalen werden aus den Eckpunkten der Dreiecke abgeleitet. Die Kovarianzmatrizen der Normalenvektoren (s. Gl. A.2.6) werden über das Fehlerfortpflanzungsgesetz (s. Gl. A.1.1) aus den Eckpunkten der Dreiecke abgeleitet. Zum Anderen werden Beschreibungslängen für unterschiedliche Modelle aus den Normalenvektoren als abgeleitete Beobachtungen eingeführt.

Die Verwendung der Beobachtungen wird folgenden Abschnitt beschrieben.

### 4.3.3 Initialisierung

Die Abhängigkeit von den Daten der Triangulation wird über die Likelihoodfunktion bestimmt (s. Abs. 3.1.5). Zur Bestimmung der Klassifikationswahrscheinlichkeiten müssen für die Knoten und Kanten Modelle unterschiedlichen Grades gegeneinander bewertet werden. Zur Bewertung wird in dieser Arbeit die Beschreibungslänge (s. Abs. 2.4) herangezogen. Für die Bestimmung des Grades der Knoten und Kanten wird ein allgemeines Polyedermodell angenommen. Ein Bezug zum Lotvektor als ausgezeichnete Richtung wird erst über die Dreiecksklassifikation hergestellt.

Bei den Dreiecken handelt es sich bei der Klassifikation um eine Orientierungsbestimmung (H,O,V). Die Orientierung zur Vertikalen kann mittels eines Parameters beschrieben werden. Daher reicht die Integration der Verteilungsfunktion über den Parameterraum der Orientierung aus.

#### 4.3.3.1 Klassifikation von Knoten

Knoten der Triangulation werden in Bezug auf ihre Ordnung klassifiziert. Ein Knoten 1-ter Ordnung ist ein Flächenknoten, ein Knoten 2-ter Ordnung ein Kantenknoten und ein Knoten 3-ter Ordnung ein Eckpunkt. Die Ordnung der Knoten bestimmt sich also hier aus der Anzahl der Normalenvektoren, die benötigt werden, um die Geometrie der angrenzenden Ebenen zu beschreiben.

Zur Beschreibung des Normalenvektors der ersten angrenzenden Ebene wird kein Parameter benötigt, da er das Referenzsystem definiert. Zur Beschreibung des zweiten Normalenvektors muß

der Winkel zum ersten Normalenvektor parametrisiert werden, d.h. es ist ein Parameter notwendig. Zur Beschreibung des dritten und jedes weiteren Normalenvektors sind dann zwei Parameter notwendig, um die Orientierung dieses Vektors im durch die die beiden ersten Vektoren definierten Koordinatensystems festzulegen.

# Normalen	u = # Parameter
1	0
2	1
3	3
...	...

Die Beschreibungslänge ergibt sich nach Gl. 2.4.1 zu

$$BL = \frac{\Omega}{2 \ln 2} + \frac{u}{2} \ln(2m) \quad (4.3.2)$$

$m, m \in \{1, \dots\}$  sei die Anzahl der beobachteten Vektoren und  $u$  die Anzahl der unbekannt Parameter.

Die jeweils  $n$  Richtungsvektoren, über die die Abweichung vom Modell bestimmt wird, werden durch das folgende Clusterverfahren ermittelt. Sei eine Menge  $\mathcal{R}$  unsicherer Richtungsvektoren  $\mathbf{r}_i, i \in \{1, \dots, m\}$  mit  $D(\mathbf{r}) = \Sigma_i$  gegeben und  $n$  die Anzahl der gesuchten Cluster. Die Richtungsvektoren seien als unkorreliert angenommen.

*Algorithmus*

1. Wähle  $n$  Vektoren  $\mathbf{v}_j$  aus der Menge  $\mathcal{R}$  aus.
2. Füge einen weiteren Vektor aus  $\mathcal{R}$  hinzu.
3. Bestimme die beiden Vektoren, die den geringsten Abstand  $\Delta$  mit

$$\begin{aligned} \Delta_{ij} &= \mathbf{v}_i - \mathbf{v}_j, \\ \Sigma_{ij} &= D(\mathbf{v}_i - \mathbf{v}_j) \text{ und} \\ \Delta &= \Delta_{ij}^t \Sigma_{ij} \Delta_{ij} \end{aligned}$$

haben.

4. Ersetze die beiden Vektoren mit dem geringsten Abstand durch ihr gewichtetes Mittel

$$\mathbf{v}_{ij} = ((\Sigma_i)^- + (\Sigma_j)^-)^- ((\Sigma_i)^- \mathbf{v}_i - (\Sigma_j)^- \mathbf{v}_j)$$

5. Wenn noch weitere unbearbeitete Vektoren in  $\mathcal{R}$  sind, fahre mit 2 fort; sonst ist die Lösung gefunden.

Die Quadratsumme der Residuen folgt als

$$\Omega = \sum_{j=1}^m \min_{i=1}^n (\mathbf{v}_i - \mathbf{r}_j)^T (\Sigma_j)^- (\mathbf{v}_i - \mathbf{r}_j),$$

wenn die  $\mathbf{v}_j$  die gefundenen  $n$  Vektoren sind.

**Auswirkung der Punktmessgenauigkeiten auf die Klassifikation der Knoten** Die a priori festgesetzte Varianz der Lagekoordinaten der Knoten der Triangulation steuert die Gewichtung zwischen dem Daten- und dem Komplexitätsterm. Durch die Wahl einer großen Varianz für die Koordinaten wird die Unterscheidbarkeit der Klassifikationen im Datenanteil geringer, so dass die Entscheidung durch die Komplexität des Modells erzwungen wird. Wird die Datengenauigkeit besser, reduziert sich relativ der Komplexitätsanteil an der Klassifikation. Dieses Verhalten der Beschreibungslänge soll nun dargelegt werden:

Wir nehmen an, dass die Punktmessgenauigkeit in allen drei Koordinaten  $\sigma_k^2$  ist.  $m$  sei die Anzahl der beobachteten Normalenvektoren in der Nachbarschaft des Punktes auf der Triangulation. Dann ergeben sich die drei Beschreibungslängen zu

$$BL_1 = \frac{1}{2 \ln 2} \frac{\mathbf{e}_1^T \mathbf{e}_1}{\sigma_k^2} \quad (4.3.3a)$$

$$BL_2 = \frac{1}{2 \ln 2} \frac{\mathbf{e}_2^T \mathbf{e}_2}{\sigma_k^2} + \frac{1}{2} lb(2 \cdot 2) \quad (4.3.3b)$$

$$BL_3 = \frac{1}{2 \ln 2} \frac{\mathbf{e}_3^T \mathbf{e}_3}{\sigma_k^2} + \frac{3}{2} lb(2 \cdot 3) \quad (4.3.3c)$$

Da alle Punktbeobachtungen in allen Koordinatenrichtungen als gleich genau angenommen wurden, ändern sich die als repräsentative Vektoren ausgewählten Vektoren nicht, daher bleiben die Residuen  $\mathbf{e}_i$  konstant, wobei gilt

$$\mathbf{e}_1^T \mathbf{e}_1 \geq \mathbf{e}_2^T \mathbf{e}_2 \geq \mathbf{e}_3^T \mathbf{e}_3. \quad (4.3.4)$$

Läßt man  $\sigma_k^2 \rightarrow 0$  streben, führt das auf eine minimale Beschreibungslänge für den dritten Fall. Für  $\sigma_k^2 \rightarrow \infty$  wird im Fall 1 die kürzeste Beschreibungslänge erreicht. Da die Funktion für  $\sigma_k^2 \geq 0$  stetig ist, wird der Fall 2 für eine mittlere Punktmessgenauigkeit erreicht.

#### 4.3.3.2 Klassifikation von Kanten

Kanten werden aufgrund der beiden direkt benachbarten Normalenvektoren der Triangulation klassifiziert. Die beiden Klassifikationen FK und BK sind möglich, was einer Repräsentation der benachbarten Dreiecke durch einen oder zwei Normalenvektoren entspricht.

Die Beschreibungslänge ergibt sich wie in Gl. 4.3.2 zu

$$BL = \frac{\Omega}{2 \ln 2} + \frac{u}{2} lb(2), \quad (4.3.5)$$

wenn  $u$  wiederum die Anzahl der Parameter der notwendigen Normalenvektoren (0 oder 1) ist.

**Auswirkung der Punktmessgenauigkeiten auf die Klassifikation der Kanten:** Es gelten die im vorhergehenden Abschnitt gemachten Anmerkungen, wobei jedoch nur je eine Beschreibungslänge für die beiden Fälle kein oder zwei Parameter bestimmt werden.

#### 4.3.3.3 Klassifikation von Dreiecken

Auf der Basis der Genauigkeiten der Punkte der Triangulation können über Fehler-Fortpflanzung die Unsicherheiten von abgeleiteten Kanten, Dreiecken und Richtungen bestimmt werden (s. Anhang A). Hier wird angenommen, dass die Richtung in einem 3D Vektor abgelegt ist und die zugehörige Kovarianzmatrix vorliegt (s. Gl. A.2.6).

$$\mathbf{r}; \Sigma_{rr} \quad (4.3.6)$$

Als Kriterium für die Bestimmung der Wahrscheinlichkeit der Klassifikation wird die Fläche gewählt, die von dem Einheitsrichtungsvektor und dem Lotrichtungsvektors  $\mathbf{r}_l$  eingeschlossen wird.

$$f = |\mathbf{r}_l \times \mathbf{r}|. \quad (4.3.7)$$

Die Varianz  $\sigma_f^2$  ergibt sich nach Gl. A.4.4 und Gl. A.4.3

Die Grenzen zwischen den drei Bereichen seien durch zwei Zenitwinkel  $g_{vo}$  und  $g_{oh}$  angegeben. Sie markieren die Grenzen zwischen vertikal und schräg bzw. schräg und horizontal. Aus diesen lassen sich Grenzflächengrößen berechnen.

$$f_{vo} = |\mathbf{r}_l \times \mathbf{r}(g_{vo})| \quad (4.3.8a)$$

$$f_{oh} = |\mathbf{r}_l \times \mathbf{r}(g_{oh})| \quad (4.3.8b)$$

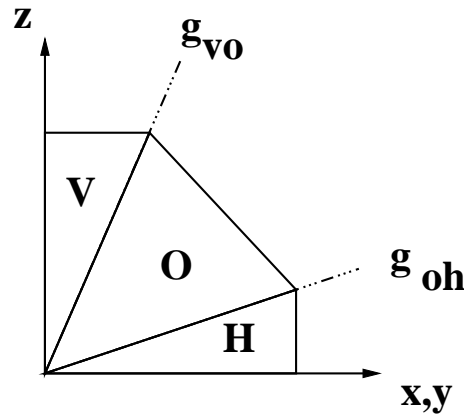


Abbildung 4.10: Richtungsklassen: Die drei Richtungsklassen decken den ersten Quadranten vollständig ab. (H=horizontal,O=schräg,V=vertikal)

Die Wahrscheinlichkeiten der unterschiedlichen Klassen sich dann durch eine Integration über die zugehörigen Modellräume zu bestimmen. Die Modellräume werden hier durch die beiden abgeleiteten Integrationsgrenzen  $f_{oh}$  und  $f_{vo}$  bestimmt (s. Abb. 4.10).

$$P(\text{horizontal}) = \int_{-\infty}^{f_{oh}} p(f, \sigma_f) df \quad (4.3.9a)$$

$$P(\text{schräg}) = \int_{f_{oh}}^{f_{vo}} p(f, \sigma_f) df \quad (4.3.9b)$$

$$P(\text{vertikal}) = \int_{f_{oh}}^{\infty} p(f, \sigma_f) df \quad (4.3.9c)$$

$f$  ist hier die Integrationsvariable. Eine Normierung ist nicht notwendig, wenn  $p(f, \sigma_f)$  eine Dichte ist, da nur über Abschnitte des Raumes der Zufallsvariablen integriert wird. Die drei Wahrscheinlichkeiten summieren zu 1. Die Klasse mit der maximalen Wahrscheinlichkeit kann als Klassifikationsergebnis ausgewählt werden.

Die den Integrationsgrenzen entsprechenden Zenitwinkel  $g_{vo}$  und  $g_{oh}$  können nur teilweise automatisch abgeleitet werden. Zwar lassen sich die Auswirkungen der morphologischen Operationen aus der Generierung der 3D Näherungsoberfläche abschätzen, dennoch sind für die Rekonstruktionsgeneralisierung zwei Parameter durch den Benutzer festzulegen: Für welche Winkel soll eine Richtung als senkrecht angesehen werden? Für welche Winkel soll eine Richtung als horizontal angesehen werden? Die Angabe dieser Parameter ermöglicht dem Benutzer aber auch, den Generalisierungsgrad festzulegen.

Ein Erlernen der Parameter aus Beispieldatensätzen für ein spezielles Generalisierungsniveau ist ebenfalls möglich.

Es ist nur sinnvoll die beiden Parameter zu beseitigen, wenn eine exakte Rekonstruktion des Gebäudes ohne Generalisierung angestrebt würde, was aber unrealistisch ist, da eine unendlich große Auflösung notwendig wäre.

#### 4.3.4 Behandlung des Randes

Zur Behandlung des Randes der Triangulation, des Teils der das Gebäude vollständig auf Geländeneiveau umgibt, werden für die Klassifikation eine Reihe von Annahmen getroffen:

- Es wird angenommen, dass ein vorhergehender Algorithmus ein Rechteck um das Gebäude gezogen hat, das das Gebäude vollständig einschließt. Daher wird angenommen, dass alle Knoten, die auf dem Rand liegen, Flächenknoten sind.



- Ebenso wird für die Randkanten angenommen, dass es sich bei diesen Kanten um Flächenkanten handelt.
- Polyederflächen, von denen mindestens einer ihrer Polygonpunkte Teil des Randes ist, dürfen als nicht senkrecht klassifiziert werden.

## 4.4 Rekonstruktion

Im Rekonstruktionsprozess wird das Ergebnis der Klassifikation auf die Objektrepräsentation übertragen. Da es in der Klassifikation zu Fehlklassifikationen kommen kann, muß überprüft werden, ob eine mögliche Rekonstruktion übernommen werden kann. Rekonstruiert werden sollen alle Parameter der Objektrepräsentation, wobei möglichst alle Klassifikationen berücksichtigt werden sollen. Daher sind Parameterschätzungen für alle Simplices der Repräsentation notwendig.

Im folgenden Abschnitt werden zunächst die Schätzprobleme charakterisiert. Anschließend werden die einzelnen Schätzer formuliert.

### 4.4.1 Charakterisierung der Schätzprobleme

Die Rekonstruktion des Gebäudes besteht in der Schätzung aller das Gebäude beschreibenden Parameter. Enthält die Triangulation  $n$  Punkte, müssen alle  $3n$  Koordinaten bestimmt werden. Zur Optimierung der Schätzung werden lokal auf der Triangulation die Parameter geschätzt, was auf eine iterative Schätzung aller Parameter der Oberfläche führt. Durch die lokale Schätzung ist eine Beurteilung der lokalen Klassifikationsergebnisse einfach möglich.

Als Beobachtungen werden die beobachteten Höhen des RasterDOMs herangezogen. Ebenen werden direkt aus den Höhenbeobachtungen bestimmt. Kanten werden als Schnitt zweier Ebenen, und Punkte als Schnitt mindestens dreier Ebenen beschrieben. Die Schätzung der Ebenen erfolgt im gemischten Modell mit Restriktionen (s. Abs. 2.3.3). Die Realisierung der Schätzung über das gemischte Modell im Gegensatz zur Realisierung mit dem GMM (s. Abs. 2.3.1) bietet den Vorteil, dass lineare Beobachtungsgleichungen genutzt werden können.

Für die Schätzung wird angenommen, dass alle Messungen, deren projizierte Lagekoordinaten innerhalb der Projektion des Dreiecks liegen, als Beobachtungen herangezogen werden können. Aufgrund von Generalisierungseffekten an den Ebenenrändern kann es vorkommen, dass Beobachtungen zu einer Ebenenschätzung herangezogen werden, die nicht Teil dieser Ebene, sondern Teil einer Nachbarebene sind. Um diese Beobachtungen für die Schätzung zu detektieren und zu löschen, wird eine robuste Schätzung durchgeführt.

### 4.4.2 Übersicht über die Schätzer

Für die lokale geometrische Korrekturen für Knoten des Graphen wird, wie bereits im vorhergehenden Abschnitt erwähnt, das gemischte Modell mit Restriktionen verwendet. Unbekannte Parameter sind die Parameter der Ebenen und das Schnittprimitiv. Beobachtungen sind die Punktkoordinaten der triangulierten Oberfläche oder der Laserscannermessungen. Die Genauigkeiten der Messungen werden auf der Basis der Kovarianzmatrizen in den Gewichtsmatrizen berücksichtigt.

Als Parametrisierung werden die Parameter der Hesseschen Normalenform (s. Gl. A.5.1) gewählt. Relevante Restriktion auf die Ebenenparameter sind die Folgenden:

- Normierung der Ebenennormalen  $\mathbf{n}$ : Restriktion

$$|\mathbf{n}|^2 = 1$$

Linearisierung:

$$2n_{10}\delta n_1 + 2n_{20}\delta n_2 + 2n_{30}\delta n_3 = 1 - |\mathbf{n}_0|^2$$

- Incidenz eines Punktes auf einer Ebene: Restriktion

$$\mathbf{n}\mathbf{x}_s - d = 0$$

Linearisierung:

$$\mathbf{x}_{s0}\delta\mathbf{n} + \mathbf{n}_0\delta\mathbf{x}_s - \delta d = d - \mathbf{x}_{s0}\mathbf{n}_0$$

- Vertikalität: Restriktion

$$n_3 = 0$$

Linearisierung:

$$\delta n_3 = 0 - n_{30}$$

- Horizontalität von Ebenen: Restriktion

$$\mathbf{n} = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

Linearisierung:

$$\delta\mathbf{n} = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} - \mathbf{n}$$

Hier dürfen nur zwei der drei Gleichungen eingeführt werden, da die Normierung bereits auf das dritte Element eine Restriktion ausübt.

Die Bestimmung der Näherungswerte der unbekannt Parameter geschieht über direkte Lösungen unter Berücksichtigung der Restriktionen. Die Näherungswerte erfüllen also bereits die Restriktionen, was zu einer Vereinfachung der Restriktionsgleichungen in den linearisierten Schätzmodellen führt.

### 4.4.3 Die Schätzmodelle im Einzelnen

Zur geometrischen Korrektur der Gebäude werden lokal geometrische Schätzungen durchgeführt. Teilweise können dazu Daten herangezogen werden, teilweise muß jedoch ausschließlich von der in dem TIN enthaltenen Information ausgegangen werden, da für senkrechte Dreiecke der Laserscanner keine Beobachtungen liefern kann (2.5D Daten).

#### 4.4.3.1 Punktschätzer

Punkte werden entsprechend A.2.2 repräsentiert. Entsprechend des Klassifikationsergebnisses wird einer der folgenden Schätzer ausgewählt:

- Flächenpunkt (FP): Sei ein Punkt von Punkten umgeben, die alle gemeinsam mit ihm in einer Ebene liegen sollen. Es werden die Ebenenparameter geschätzt und der Punkt in die Ebene verschoben.
- Bruchkantenpunkt (KP): Ein Punkte liege auf einer Bruchkante. Es werden die beiden angrenzenden Ebenen geschätzt. Der zu rekonstruierende Punkt wird als Beobachtung eingeführt und an die geschätzten Koordinaten verschoben.
- Eckpunkt (EP): Sei ein Punkte ein Eckpunkt, in dem sich drei oder mehr Ebenen schneiden. Es werden die Parameter der angrenzenden Ebenen geschätzt. Als weitere Bedingung wird die Schnittbedingung für die drei oder mehr Ebenen eingeführt. Der Knoten selbst wird als Beobachtung eingeführt und an die geschätzten Koordinaten verschoben.

#### 4.4.3.2 Kantenschätzer

Im Folgenden werden die möglichen Fälle der geometrischen Konstellationen beschrieben. Allen gemeinsam ist, dass die Ebenen sich in der betrachteten Kante schneiden müssen oder die Ebenen identisch sind. Ein Schnitt ist notwendig für Bruchkanten. Für Flächenkanten müssen beide Ebenen identisch sein.

**Bruchkanten** Für Bruchkanten müssen unterschiedliche Fälle unterschieden werden:

- **Zwei horizontale Dreiecke:** Der Fall zweier horizontaler Kanten, kann nicht vorkommen, da entweder ein senkrechtetes Dreieck zwischen den Dreiecken liegen muß oder aber die Dreiecke in einer identischen Ebene liegen müssen. Damit müßte es sich aber um eine Flächenkante handeln.
- **Ein horizontales und ein vertikales Dreieck:** Da die vertikale Ebene ist nicht beobachtbar ist und beide Dreiecke ähnlich gewichtet werden sollen, können nicht die Laserscannerdaten und Knotenpunkte gleichgewichtig eingefügt werden. Daher werden nur die Knoten der Triangulation verwandt.
- **Zwei vertikale Dreiecke:** Da es sich um eine Bruchkante handelt, haben die Normalenvektoren der beiden senkrechten Dreiecke unterschiedliche Azimute.
- **Ein vertikales und ein schräges Dreieck:** Dieser Fall verhält sich wie der vorhergehende Fall, ohne dass jedoch für den Normalenvektor der schrägen Ebene Horizontalität verlangt werde.
- **Zwei schräge Dreiecke:** In diesem Fall wird durch die Schätzung keine zusätzliche Fixierung der Geometrie erreicht, da die beiden Dreiecke frei beweglich sind. Es werden die Laserscannerdaten als Beobachtungen verwandt.
- **Ein horizontales und ein schräges Dreieck:** Dieser Fall wird wie der vorhergehende Fall behandelt, mit dem Unterschied, dass für die horizontale Ebene der Normalenvektor durch Restriktionen als vertikal festgelegt wird.

**Flächenkanten** Für Flächenkanten können die unten beschriebenen Schätzer für Dreiecke verwandt werden, wenn der Begriff Dreieck zu Viereck verallgemeinert wird. Es werden also in den Schätzungen alle Daten verwendet, deren Fußpunkte innerhalb der Projektion der beiden Dreiecke in der horizontale Ebene liegen. Im Falle von senkrechten Ebenen werden die vier Knoten der Triangulation berücksichtigt.

#### 4.4.3.3 Dreiecksschätzer

Für die drei möglichen Klassifikationen von Dreiecken (H,O,V) sind die folgenden Schätzer notwendig:

- **Vertikales Dreieck:** Zur Korrektur einer vertikalen Ebene werden die drei Eckpunkte des Dreiecks als Beobachtungen verwandt. Die Restriktion der Vertikalität führt dann auf eine Redundanz 1.
- **Schräges Dreieck:** Es werden die drei freien Ebenenparameter mittels der Rasterpunkte des DOMs als freie 3D Ebene geschätzt.
- **Horizontales Dreieck:** Für ein horizontales Dreieck bedarf es nur der Schätzung einer mittleren Höhe. Auch hier werden die Rasterpunkte des Digitalen Oberflächenmodells als Beobachtungen eingeführt.<sup>7</sup>

<sup>7</sup>Zur einheitlichen Behandlung der Schätzer ist jedoch eine Realisierung über Restriktionen mit einem allgemeinen Ebenenansatz gewählt worden.

#### 4.4.4 Robuste Schätzung

Die robusten Schätzer sind in dieser Arbeit kein zentrales Element, werden jedoch zur Schätzung der Ebenenparameter verwendet. Es wurde dazu ein einfacher auf einem Schwellwert in den Abweichungen der Beobachtungen vom Näherungsmodell basierender robuster Schätzer verwandt (s. Abs. 2.5). Dazu wurde angenommen, dass die beobachteten Punkte maximal  $dy = 1m$  von der näherungsweise aus der Triangulation genommenen Beobachtung abweicht. Diese einfache Realisierung hat den Vorteil, dass die Komplexität der Näherungswertsuche und die Selektion der Ausreisser in den Beobachtungen nicht wie bei anderen robusten Schätzverfahren (FISCHLER UND BOLLES 1981, HUBER 1981 oder ROUSSEEUW UND LEROY 1987) anwächst, hat aber auch den Nachteil, dass die Näherungswerte nicht durch ein robustes Verfahren bestimmt werden. Es wird jedoch angenommen, dass die Näherungswerte ausreichend gut sind.

#### 4.4.5 Behandlung des Randes in der Rekonstruktion

Simplices auf dem Rand der betrachteten Oberfläche werden geometrisch nicht verändert, da angenommen wird, dass die Oberflächen über das Gebäude hinaus reichen und die Umgebung von Gebäuden nicht modelliert ist.

# Kapitel 5

## Ergebnisse der Realisierung

Ziel dieses Kapitels ist es, anhand von Beispielen die Möglichkeiten und auch Probleme des beschriebenen Verfahrens aufzuzeigen. Ein synthetischer und ein realer Datensatz werden berechnet.

### 5.1 Synthetisches Beispiel

Als synthetischer Datensatz wurde das Digitale Oberflächenmodell eines Bungalows generiert. Das Gebäude hat eine Länge von  $15m$ , eine Breite von  $7m$  und eine Höhe von  $7m$  und entspricht damit in der Ausdehnung einem realen Gebäude. Die Rasterweite wurde als  $0.20m$  angenommen.

Es werden drei Tests auf diesem synthetischen Datensatz vorgenommen. Die Tests variieren im Lösungsalgorithmus und im angenommenen Rauschen. Abbildung 5.1 gibt eine Aufstellung. Für die

	Lösungs- algorithmus	Rauschen $\sigma_x = \sigma_y = \sigma_z$
Variante a	ICM	kein
Variante b	Metropolis	kein
Variante c	ICM	$0.1m$

Abbildung 5.1: Übersicht über die Tests auf dem synthetischen Datensatz.

drei Beispiele sind die Ergebnisse der Generierung der Näherungsoberfläche identisch, da dieser Schritt nicht von den variierten Parametern abhängt. In Abbildung 5.2 sind Teilergebnisse dieser Vorverarbeitung gezeigt. Die abgeleitete Näherungsoberfläche ist ideal. Das Gebäude wird durch 12 Knoten repräsentiert, die korrekt in der Triangulation verkantet sind. Alle Knoten haben eine fehlerfreie Höhe. Die Abschrägung der Wände des Gebäudes ergibt sich durch den morphologischen Algorithmus. Es wird deutlich, dass zur Klassifikation diese durch den Algorithmus bedingte Abschrägung berücksichtigt werden muss.

Beginnend mit der a priori Klassifikation der Knoten variieren die Beispiele. In Abbildung 5.3 ist das Ergebnis bei Verwendung ICM-Algorithmusses gezeigt<sup>1</sup>. Die a priori Klassifikation liefert ein ideales Klassifikationsergebnis. Alle Knoten, Kanten und Dreiecke sind bereits richtig klassifiziert worden, sodass die Iteration des ICM Algorithmus sofort nach dem ersten Iterationsschritt abgebrochen wird. Abbildung 5.5 dokumentiert die ideale Klassifikation, indem dort die posteriori Chancen visualisiert sind. Es sind transformierte posteriori Chancen dargestellt, deren numerische Werte mit

$$\bar{o} = \frac{p(s^*) + 0.5}{p(s_{max}) + 0.5} \quad (5.1.1)$$

<sup>1</sup>Legende der Klassen: FP (blau), KP (rot), EP (grün), FK (blau), BK (grün), H (gelb), V (blau), O (magenta)




Abbildung 5.2: Synthetischer Datensatz “Bungalow”: (zeilenweise) 1) synthetisches Raster DOM, 2+3) Gradienten in erodierten DOMs in Zeilen und Spalten, 4+5) Gradienten des dilatierten DOMs in Zeilen und Spalten, 6) FEX-Ergebnis auf Gradienten des erodierten DOMs, 7) FEX-Ergebnis auf Gradienten des dilatierten DOMs, 8) Näherungsoberfläche 9) Übersicht der Abbildung




Abbildung 5.3: Synthetischer Datensatz (Variante a und b): a priori Klassifikation. Die Legende ist in Anhang B.5 zu finden.

bestimmt worden sind, um einen Nenner identisch 0 zu vermeiden.  $s^*$  bezeichnet dabei die Klassifikation selbst und  $s_{max}$  eine mögliche andere Klasse mit der maximalen Wahrscheinlichkeit. Handelt es sich um eine Klassifikation mit der Klassenwahrscheinlichkeit  $p(s^*) = 1$  ergibt sich eine posteriori Chance von 3. Wäre ein Klasse mit der Wahrscheinlichkeit  $p(s^*) = 0$  ausgewählt, ergäbe sich  $\frac{1}{3}$ . Das Diagramm zeigt ideale Klassifikationen für fast alle Klassen. Die maximal mögliche posteriori Chancen werden nur für die vertikalen Wände nicht immer erreicht.




Abbildung 5.4: Synthetischer Datensatz (Variante a): rekonstruiertes Gebäude.

In der geometrischen Korrektur werden hier ausschließlich die Orientierungen der Dreiecke an die Daten und die Klassifikationen angepasst. Eine Ausrichtung der Dreiecke zu ebenen Gebäude-seiten wird so nicht erreicht, da die Verknüpfung zwischen benachbarten Ebenen nicht genutzt wird. Die Gesamtwahrscheinlichkeit für die Klassifikation der Triangulation ergibt sich zu 0.934915. Das geometrische Mittel der lokalen Wahrscheinlichkeiten ist 0.99957. Die Abweichungen von der idealen Klassifikation mit der Wahrscheinlichkeit 1 resultieren aus der nicht abschließend korrigierten Geometrie.




Abbildung 5.5: Synthetischer Datensatz (Variante a): Transformierte posteriori Chancen in der Klassifikation in Abhängigkeit der Klassifikation (0=FP, 1=KP, 2=EP, 3=FK, 4=BK, 5=H, 6=V)

Die zweite Variante startet mit der a priori Klassifikation in Abbildung 5.3. Die Iterationen der Klassifikation führen im Metropolis-Algorithmus nach 500 Iterationen auf das in Abbildung 5.6 dargestellte Ergebnis, wobei der in Abbildung 5.7 dargestellte Temperaturverlauf verwandt wur-






Abbildung 5.6: Synthetischer Datensatz (Variante b): Klassifikation nach 500 Iterationen




Abbildung 5.7: Verlauf der diskreten Temperatur für den Metropolis-Algorithmus mit  $T_0 = 10.0$

de. Aufgrund der hohen Anfangsenergie ändern sich im ersten Iterationsschritt der Klassifikation 23 Klassenzuweisungen. Die a priori Klassifikation hat nur einen geringen Einfluss. Im Ergebnis nach 500 Iterationen sind einzelne Eckpunkte falsch als Kantenpunkte klassifiziert worden. Die Klassifikationswahrscheinlichkeit des Netzes liegt unterhalb der Wahrscheinlichkeit für die a priori Klassifikation. Die Rekonstruktion des Gebäudes unterscheidet sich nicht von der Variante a,




Abbildung 5.8: Synthetischer Datensatz (Variante b): Transformierte posteriori Chancen in der ersten Klassifikation in Abhängigkeit der Klassifikation. (0=FP, 1=KP, 2=EP, 3=FK, 4=BK, 5=H, 6=V)




Abbildung 5.9: Synthetischer Datensatz (Variante b): rekonstruiertes Gebäude

da die Klassifikationen der Flächen gleich sind und nur diese zur Rekonstruktion herangezogen werden.

Das stochastische Verhalten des Metropolis-Algorithmusses wird beim Vergleich der Abbildungen 5.5 und 5.8 deutlich. Im Fall des deterministischen Ansatzes (Abb. 5.5) werden nur Klassifikationen mit maximaler Wahrscheinlichkeit ausgewählt. Beim stochastischen Ansatz (Abb. 5.8) werden ebenso Klassifikationen mit teilweise sehr geringen Wahrscheinlichkeiten ausgewählt.

Für die Variante c wird auf die Näherungsoberfläche ein Rauschen von  $\sigma_x = \sigma_y = \sigma_z = 0.1m$  aufmodelliert, damit die Klassifikation unabhängig von der Näherungsflächengenerierung beurteilt werden kann. Das Rauschen wird für die Klassifikation als nicht bekannt vorausgesetzt. Aufgrund




Abbildung 5.10: Synthetischer Datensatz (Variante c): a priori Klassifikation: Fünf Knoten sind falsch klassifiziert worden. Die Fehlklassifikationen passen semantisch nicht zu den Klassifikationen in der Nachbarschaft.

der zu klein angenommen Varianz ändert sich die a priori Klassifikation (s. Abb. 5.10). Es ergeben sich fehlerhafte Klassifikationen für ein Dreieck innerhalb des Daches und zwei Traufkanteneckknoten und die Grundrisseckpunkte. Teilweise kann das Nachbarschaftswissen diese Fehler




Abbildung 5.11: Synthetischer Datensatz (Variante c): Klassifikation nach 100 Iterationen: Die Klassifikationen sind alle semantisch sinnvoll. Dennoch sind die aufgehenden Kanten und einige Eckpunkte falsch klassifiziert, was aber nur ein globales Verfahren feststellen könnte.

korrigieren und führt auf ein zur Variante b vergleichbares Ergebnis (s. Abb. 5.12). Die Dreiecke sind richtig klassifiziert worden. Die aufgehenden Gebäudeecken können nicht von Flächenkanten unterschieden werden. Dieses ist auf den allgemeinen Polyederansatz, der für die Kanten und Punktklassifikation ohne eine ausgezeichnete Lotrichtung arbeitet, zurückzuführen.

Die Versuche mit dem synthetischen Beispiel zeigen die folgenden Eigenschaften des Verfahrens:

- Da der ICM-Algorithmus bereits nach der ersten Iteration die Klassifikation abbricht, enthält die Bestimmung der a priori Klassifikation bereits genügend Informationen für eine korrekte Klassifikation.
- Die Wahrscheinlichkeiten unterschiedlicher Netzrealisierungen haben nur geringe Differenzen. Dies betrifft die a priori als auch die posteriori Klassifikationen. Selbst nach 18000 Iterationen mit einer abschließenden Temperatur von 0.102 ( $T_o = 1.0$ ) war für die idealen Daten bei Verwendung des Metropolis-Algorithmusses noch kein stabiles System erreicht.
- Durch die Berücksichtigung des Nachbarschaftswissens wird das System nur wenig präzisiert. Einzelne Korrekturen sind jedoch möglich.




Abbildung 5.12: Synthetischer Datensatz (Variante c): Rekonstruiertes Gebäude




Abbildung 5.13: Synthetischer Datensatz (Variante c): Transformierte posteriori Chancen der Klassifikation im ersten (links) und zweiten (rechts) globalen Iterationsschritt in Abhängigkeit der Klassifikation (0=FP, 1=KP, 2=EP, 3=FK, 4=BK, 5=H, 6=V, 7=O)

- Die Rekonstruktion führt auf eine Verbesserung der Geometrie des Gebäudes. Dennoch reicht die Rekonstruktion nur der Dreiecksflächen mit den Restriktionen aus der Klassifikation für eine vollständige Gebäuderekonstruktion nicht aus. Hier sollten auch Kanten und Knoten des simplizialen Komplexes rekonstruiert werden.
- Die Klassifikation der Ordnung der Punkte ist unsicherer als die Klassifikation von Kanten und Dreiecken.

## 5.2 Reale Daten

In diesem Abschnitt werden Ergebnisse eines realen Datensatzes gezeigt. Es handelt sich um einen Ausschnitt des Testdatensatzes “Ravensburg”, der von der Firma TOPOSYS (Ravensburg) zur Verfügung gestellt wurde. Die Bodenaufösung des Rasters ist  $0.6 \times 0.6m^2$ .

In LOHR UND EIBERT 1995 wird eine Genauigkeit für die physikalische Streckenmessung des verwandten Laser von  $0.1m$  angegeben. Die Streckenmessgenauigkeit beinhaltet aber nur einen Teil der für die Rekonstruktion relevanten Fehler, da zum Einen das DOM durch ein Interpolationsverfahren abgeleitet wird, was die theoretische Genauigkeit der Höhen steigert, und zum Zweiten sich die Messungenauigkeit in der Positionsbestimmung des Sensors (Äußere Orientierung) für die endgültigen Höhen auswirkt. Desweiteren repräsentiert eine Höhe im Raster nur eine mittlere Höhe für eine Fläche von  $0.36m^2$ . Die gemittelten Höhen können insbesondere an Bruchkanten im realen DOM stark davon stark abweichen. Daher wurden hier Rasterpunktmessgenauigkeiten von  $\sigma_x = 0.6$ ,  $\sigma_y = 0.6$  und  $\sigma_z = 0.5$  angenommen.

Im folgenden Abschnitt werden die Ergebnisse der Vorverarbeitung gezeigt. Danach werden vier Alternativen der Klassifikation und Rekonstruktion beschrieben, um die Einflüsse des Lösungsalgorithmus der Klassifikation und des angenommenen Modells zu verdeutlichen. An den Beispielen wird auch die Fähigkeit des Algorithmus, den Gebäudetyp der interpretierten und rekonstruierten Gebäude zu bestimmen, deutlich.

### 5.2.1 Vorverarbeitung

In Abbildung 5.14 werden Ergebnisse der Vorverarbeitung gezeigt. In den Diagrammen lassen sich die folgenden Beobachtungen machen:

- Das DOM: Das DOM zeigt ein detektiertes Gebäude, das schräg zur Zeilen- und Spaltenrichtung liegt. Die Höhen sind in Grauwerten kodiert. Helle Grauwerte stehen für eine große Höhe, dunkle Grauwerte meinen eine niedrige Höhe. Es ist zu erkennen, dass die Gebäudeseiten stark gerastert sind. Die Umgebung des Gebäudes hat keine konstante Höhe. In der linken oberen Ecke zeigt einen Höhenversatz.
- Die Gradientenoberflächenmodelle: Starke Gradienten sind durch hohe Grauwerte repräsentiert, schwache Gradienten durch dunkle. In den vier Gradientenbildern prägen sich die Gebäudeseiten unterschiedlich deutlich aus. Die Rasterung der Seiten bleibt jedoch erhalten. Im Umfeld des Gebäudes werden Pixel mit starken Gradienten gefunden, die nicht Teil des Gebäudes sind.
- Die Merkmalsextraktion: Die Merkmalsextraktion FEX auf dem dilatierten und erodierten Bild liefert einzelne Punkte und im dilatierten Bild auch mehrere Kanten.
- Die Kombination und Triangulierung: Das Punktselektionsverfahren und die nachfolgende Triangulierung liefern eine Gebäudebeschreibung, deren Triangulationsknoten jedoch im Sinne der Gebäudetopologie noch in einem interaktiven Schritt verbessert werden.
- Die Näherungsoberfläche: Die Näherungsfläche enthält neben den Gebäudepunkten einen weiteren Punkt neben dem Gebäude. Keine Traufkante ist vollständig repräsentiert. An je zwei Traufkanten fehlen ein oder zwei Punkte.




Abbildung 5.14: Realer Datensatz "Block1": (zeilenweise) RasterDOM, Gradienten in erodierten DOMs in Zeilen und Spalten, Gradienten des dilatierten DOMs in Zeilen und Spalten, FEX-Ergebnis auf Gradienten des erodierten DOMs, FEX-Ergebnis auf Gradienten des dilatierten DOMs, Näherungsoberfläche mit Höhenschwellwert 449.0m und gesetzter Grundhöhe von 440.0m, editierte Näherungsoberfläche

Die Vorverarbeitung liefert also eine Gebäudebeschreibung die nur teilweise den Vorgaben der Modellierung entspricht. Im nächsten Abschnitt wird gezeigt, wie die Klassifikation und die Rekonstruktion auf der Näherungsoberfläche agiert.

### 5.2.2 Klassifikation und Rekonstruktion

Nach der Generierung der Näherungsoberfläche werden die Knoten allein aufgrund ihrer Geometrie a priori klassifiziert. Zur Verdeutlichung des Effekts der Schwellwertbildung, soll zunächst die a priori Klassifikation ohne Berücksichtigung des Schwellwertes in der Generierung der Triangulierung bestimmt werden. Das Ergebnis ist in Abbildung 5.15 gezeigt. In der Umgebung des




Abbildung 5.15: A priori Klassifikation der Simplexes der Triangulation ohne Berücksichtigung einer Umgebungshöhe und einer Segmentierung.

Gebäudes treten nicht modellierte Effekte auf:

- Es werden zusätzliche Knoten identifiziert.
- Die Dreiecke sind teilweise stark geneigt.
- In der Umgebung erscheinen Bruchkanten aufgrund einer terrassenartigen Struktur.



Um die nicht modellierten Effekte in der Umgebung des Gebäudes zu verringern, verwenden wir nun den bereits in Abbildung 5.14 beschriebene Höhengschwellwert, unterhalb dem alle Triangulationspunkte einer konstanten horizontalen das Gebäude umgebenden Ebene angehören sollen. Durch diese Segmentierung kann zunächst eine gute a priori Klassifikation erreicht werden, da die extrahierten Strukturen (markante Punkte, Bruchkanten) als Teile der Umgebungsebene klassifiziert werden. Wie die Abbildung 5.16 zeigt, sind dann in der a priori Klassifikation alle Knoten




Abbildung 5.16: A priori Klassifikation der Simplexes der Triangulation (mit einer Umgebungshöhe von 440m und einem Höhengschwellwert von 449m).

und Kanten richtig in ihrer Gebäudebedeutung klassifiziert worden. Die Flächen einer Wand sind jedoch fälschlicherweise als schräg klassifiziert worden, obwohl sie nach dem Gebäudemodell senkrecht sind. Die Abschrägung der Dreiecke geht jedoch hier über den erwarteten Zenitwinkel für die Ebenenklassifikation hinaus. Die priori Klassifikationen dienen nun als Grundlage für alle nachfolgenden Tests.

Es wurden im einzelnen die folgenden Tests definiert:

	Lösungsalgorithmus	Gebäudemodell
Variante a	ICM	“Viereckiges Flachdachhaus”
Variante b	Metropolis	“Walmdachhaus”
Variante c	ICM	“Viereckiges Flachdachhaus”
Variante d	Metropolis	“Walmdachhaus”

Die vier Varianten zeigen alle Kombinationen zwischen den realisierten Optimierungsalgorithmen und Gebäudetypmodellen.

**Variante a** In der Variante a wird das “viereckige Flachdachhaus” aus Gebäudemodell verwendet. Die Lösung des Zufallsfeldes wird mit dem ICM-Algorithmus gesucht. Das Ergebnis dieses Versuches ist in den Abbildungen 5.17 und 5.18 gezeigt. Die Knoten des Zufallsfeldes (Punkte, Kanten und Dreiecke) sind alle richtig klassifiziert. Der Vergleich zu Abbildung 5.16 zeigt eine Verbesserung der Geometrie des Gebäudes.





Abbildung 5.17: Realer Datensatz (Variante a): ICM-Algorithmus, Abbruch bei keinen Klassifikationsänderungen und Summe der Punktbewegungen unterhalb von 1.0 m, Gebäudemodell “Bungalow”

Als horizontal klassifizierte Ebenen werden vollständig korrigiert. Die Koplanarität der Dreiecksseiten der Gebäudeseiten wird jedoch nicht erreicht, da hier nur einzelne Dreiecke korrigiert worden sind. Die separaten Schätzungen der Dreiecksebenen können nicht eine Koplanarität aller Dreiecke einer Gebäudeseite bewirken. Ebenso ist die Lage der vertikalen Ebenen unbestimmt, da die vertikalen Ebenen nur durch das Traufkantenpolygon und das Grundrisspolygon bestimmt werden, die jedoch beide um einen konstanten Betrag durch die Vorverarbeitung ungenau sind. Zwischen diesen beiden Ebenen ist ein “pendeln” der Punkte in den vertikalen Ebenen möglich.

Das Beispiel zeigt, dass das Nachbarschaftsmodell des “viereckigen Flachdachhauses” zu keinen Fehlklassifikationen führt und daher auf das in lokalen bedingten Wahrscheinlichkeiten realisierte




Abbildung 5.18: Realer Datensatz (Variante a): Ergebnis ohne redundante Bruchkantenpunkte, Flächenpunkte und Flächenkanten.

Modell bestätigt wird. Die geometrische Korrektur führt zur Verbesserung der Geometrie des Gebäudes.

Die Variante a schränkt des Lösungsraums am stärksten ein. In zwei Iterationen wird die endgültige Klassifikation mit insgesamt 6 (5+1) Klassifikationsänderungen (s. Abb. 5.2.2 links) erreicht. Die Gesamtwahrscheinlichkeit (s. Abb. 5.2.2 rechts) des Feldes steigt in zwei Schritten. Das Beispiel zeigt, dass die Näherungslösung der a priori Klassifikation schon sehr nah an der endgültigen und optimalen Lösung liegt. Durch die Anwendung des Metropolis-Algorithmusses ist daher kein signifikant besseres Ergebnis zu erwarten. Dennoch wird der Versuch mit dem Metropolis-Algorithmus als Lösungsverfahren im Folgenden beschrieben.

**Variante b** Im Gegensatz zur Variante a wird hier der stochastische Lösungsansatz des Metropolis-Algorithmusses gewählt. Durch zufälliges Ablehnen der lokal besten Klassifikation soll das globale Wahrscheinlichkeitsmaximum von lokalen Wahrscheinlichkeitsmaxima unterschieden werden.

Das Ergebnis der Klassifikation ist in Abbildung 5.20 gezeigt. Es ist identisch zu dem Klassifikationsergebnis der Testvariante a, wird jedoch erst nach dem dritten Iterationsdurchlauf von Klassifikation und Rekonstruktion erreicht.

Im Verlauf der Funktion der Anzahl der Änderungen je Iteration ist deutlich zu erkennen, dass trotz einzelner Iterationen ohne Änderungen, in nachfolgenden Iterationsschritten wieder Änderungen aufgrund des randomisierten Ansatzes vorkommen (s. Abb. 5.21 bis 5.23). Insbesondere die

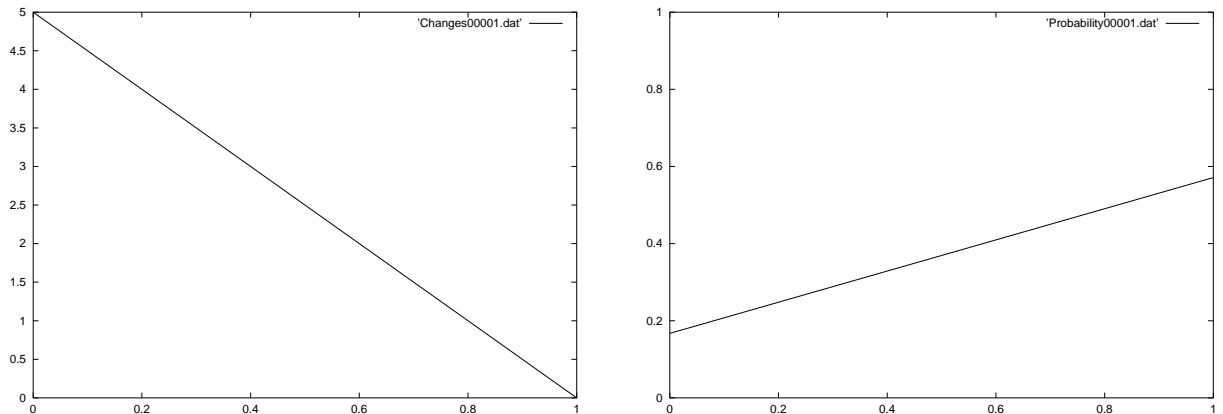


Abbildung 5.19: Realer Datensatz (Variante a): Verlauf der Anzahl der Änderungen der Klassifikation und der Gesamtwahrscheinlichkeit in den Klassifikationsiterationen.

geometrische Korrektur in der zweiten Iteration führt wieder zu Änderungen der Klassifikation.

**Variante c und d** Für die Testvarianten c und d wurde das Walmdachhausmodell verwandt. Mit diesem Test wird deutlich, dass mit dem Nachbarschaftsmodell des Walmdachhauses nur sehr geringe Gesamtwahrscheinlichkeiten sowohl für den ICM- als auch für den Metropolis-Algorithmus erreicht werden können (s. Abb. 5.26). Diese Beispiele demonstrieren somit die Fähigkeit des Zufallsfeldes über die Gesamtwahrscheinlichkeit Gebäude unterschiedlichen Typs zu unterscheiden.

Als Lösungsverfahren wurde für das Ergebnis der Variante c (s. Abb. 5.24) der ICM-Algorithmus verwandt. Die Iterationen wurden bei einer konstanten Klassifikation, hier nach 2 Iterationen abgebrochen. Es treten Fehlklassifikationen auf der Traufkante und in den Dachflächen auf. Die Klassifikationswahrscheinlichkeit ist sehr gering.

Für die Variante d wurde der Metropolis-Algorithmus verwandt. Die Iterationen der Klassifikation wurden nach 100 Iterationen beendet. Es ergeben sich geringe Wahrscheinlichkeiten der Klassifikation für das gesamte Zufallsfeld (s. Abb. 5.26 rechts) und eine große Anzahl von Fehlklassifikationen (s. Abb. 5.25).

Im Vergleich zu den Ergebnissen mit dem Flachdachhausmodell ergeben sich weitaus geringere Wahrscheinlichkeiten der Klassifikation des gesamten Zufallsfeldes (s. Abb. 5.21 und 5.26 rechts). Ebenso variieren die lokalen Klassifikationen stärker (s. Abb. 5.26 links).

Sollen nicht zwei (oder mehrere) Gebäudetypen gegeneinander abgegrenzt werden, sondern soll geprüft werden, ob es sich bei dem Gebäude um ein Walmdachhaus handelt, kann anhand der folgenden Indizien eine Entscheidung getroffen:

- Der Klassifikationsprozess liefert eine geringe Gesamtwahrscheinlichkeit für die Klassifikation des gesamten Zufallsfeldes (internes Beurteilungskriterium).
- Die Anzahl der Klassifikationsänderungen konvergiert nicht (internes Beurteilungskriterium).
- Es existiert eine große Anzahl von Fehlklassifikation in Knoten des Zufallsfeldes (externes Beurteilungskriterium).

### 5.3 Vergleich der beiden Lösungsverfahren des MRFS

Vergleiche zwischen den unterschiedlichen Lösungsstrategien für Zufallsfeldern werden von einigen Autoren bereits unternommen. Einer der ersten war BLAKE 1989. Für die Oberflächenrekonstruktion mit Hilfe von *Shape from Shading* und Optischem Fluss hat er empirisch gefunden, dass die




Abbildung 5.20: Realer Datensatz (Variante b): Rekonstruktionsergebnis nach der dritten und gleichzeitig letzten geometrischen Iteration.

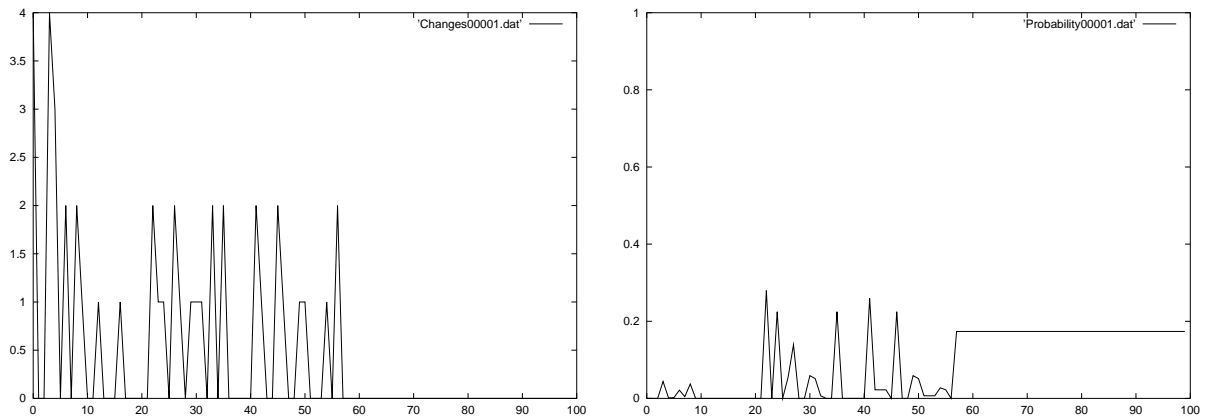


Abbildung 5.21: Realer Datensatz (Variante b): Verlauf der Anzahl der Änderungen der Klassifikation und der Gesamtwahrscheinlichkeit in den ersten Klassifikationsiterationen.

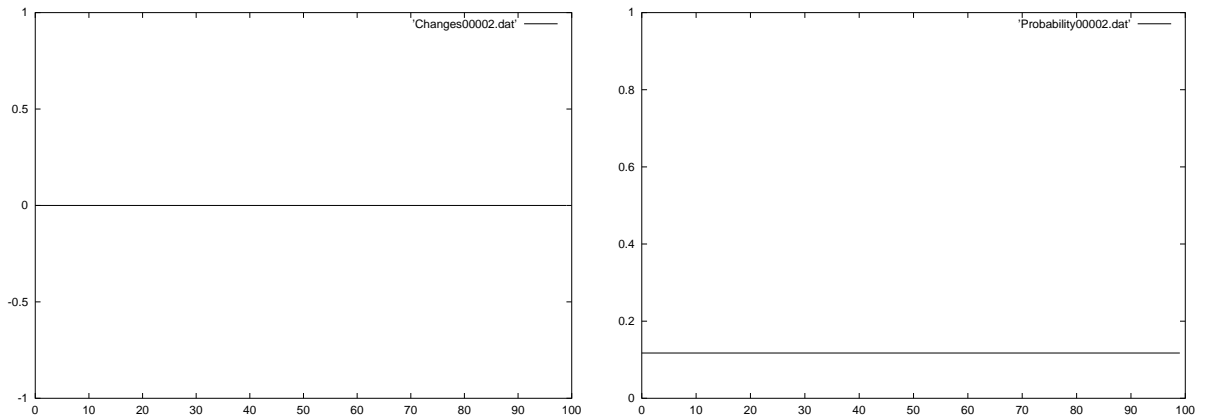


Abbildung 5.22: Realer Datensatz (Variante b): Verlauf der Anzahl der Änderungen der Klassifikation (links) und der Gesamtwahrscheinlichkeit in den zweiten Klassifikationsiterationen (rechts).




Abbildung 5.23: Realer Datensatz (Variante b): Verlauf der Anzahl der Änderungen der Klassifikation (links) und der Gesamtwahrscheinlichkeit in den dritten Klassifikationsiterationen (rechts).




Abbildung 5.24: Realer Datensatz (Variante c): Ergebnis der integrierten Interpretation und Rekonstruktion.




Abbildung 5.25: Realer Datensatz (Variante d): Ergebnis der Klassifikation und Rekonstruktion.






Abbildung 5.26: Realer Datensatz (Variante d): Verlauf der Anzahl der Änderungen der Klassifikationen (links) und der Gesamtwahrscheinlichkeit in den Klassifikationsiterationen (rechts). Die Gesamtwahrscheinlichkeiten liegen alle unterhalb von  $10^{-4}$ .

deterministischen Algorithmen den stochastischen Algorithmen in seiner Testumgebung überlegen waren.

Die empirischen Untersuchungen in dieser Arbeit deuten ebenso die Überlegenheit des deterministischen Verfahrens als das bessere für diese Aufstellung und Lösungsalgorithmus an. Die Klassifikationsergebnisse weichen weniger von der idealen Klassifikation ab.

Die Beispiele zeigen, dass die Näherungslösung wichtig für die Bestimmung einer korrekten Klassifikation ist. Das Nachbarschaftswissen hat für die Klassifikation nur wenig Bedeutung. Die Nachbarschaften führen zwar zur Verbesserung des Klassifikationsergebnisses. Dennoch ist die Korrekturfähigkeit der Lösungsalgorithmen des Zufallsfeldes bei den gewählten relativ kleinen Nachbarschaften gering.

## 5.4 Beurteilung des Rekonstruktionsergebnisses

Für die Rekonstruktion wurden ausschließlich die Schätzer für die vertikale, schräge und horizontale Ebene verwandt, weil sie sich empirisch als die robustesten Schätzer erwiesen haben. Aufgrund der großen Anzahl der Beobachtungen und der daraus folgenden hohen Redundanz für schräge und horizontale Ebenen war eine sichere Schätzung der Ebenenparameter möglich. Die Schätzungen für senkrechte Ebenen führen aufgrund der geringen Redundanz von eins auf unsichere Schätzergebnisse. In der Schätzung von Kanten und Knoten sind die unterschiedlichen Redundanzanteil der beiden Ebenenparameter zu berücksichtigen.

Die ausschließliche Verwendung der Flächenschätzer führt dazu, dass zum Einen die Komplanarität von in einer Ebene liegenden Dreiecken nicht sichergestellt ist. Zum anderen werden die Kanten und Knoten nur iterativ in Abhängigkeit von den benachbarten Dreiecken korrigiert. Eine gemeinsame Bestimmung der Lage ist nur über die Knoten- oder Kantenschätzung möglich. Daher sollten die Kanten- und Knotenschätzer für eine Weiterentwicklung ebenfalls implementiert werden, denn, obwohl sie teilweise eine geringe Redundanz aufweisen, führen die Restriktionen zwischen den Dreiecken zu einer Verkettung der Dreiecke untereinander.

Für die iterative Schätzung der Gebäudegeometrie über lokale Schätzungen wird angenommen, dass die Schätzung der Geometrie in lokale Schätzung näherungsweise separierbar ist. Werden nur kleine Korrekturen an die Näherungswerte der Parameter pro Schätzung angebracht, wird durch die Beispiele empirisch die Separierbarkeit bestätigt.

Abschließend muss anhand der realen Ergebnisse festgestellt werden, dass die Qualität des verwandten Datenmaterials für die Interpretation und Rekonstruktion mit der beschriebenen po-

lymorphen Modellierung unzureichend ist. Dennoch ist bei den aktuellen Weiterentwicklungen der Laserscantechnologie in Zukunft mit höheraufgelösten und qualitativ besseren Daten zu rechnen und damit auch für Laserscannerdaten mit einer besseren Einsetzbarkeit des Verfahrens.

# Kapitel 6

## Zusammenfassung und Ausblick

### 6.1 Zusammenfassung

In der Arbeit wurde ein neues Verfahren zur integrierten Interpretation und Rekonstruktion von Gebäudedaten beschrieben. Dabei ermöglicht das vorgestellte Verfahren die Verwendung von multisensoriellen Daten. Es wird eine generische, Topologie basierte Repräsentation der Gebäude gewählt, die die Ausnutzung geometrischer und vor allem semantischer Eigenschaften des Objektes “Gebäude” ermöglicht.

Zur Lösung des Interpretations- und Rekonstruktionsproblems wurde ein iterativer Prozess definiert, der zunächst die Klassifikation und dann die Rekonstruktion löst. Iterationen dieses Schemas sind möglich. Verkoppelte Zufallsfelder auf triangulierten Graphen werden für die Klassifikation mit zwei unterschiedlichen Lösungsverfahren (ICM und Variante des Metropolis-Algorithmus) optimiert. Die anschließende Rekonstruktion erfolgt lokal durch statistische Schätzverfahren.

Das Verfahren der integrierten Interpretation und Rekonstruktion wurde unter Verwendung von Laserdaten implementiert. Eine Merkmalsextraktion wurde zur Ableitung einer Näherungsrepräsentation des Gebäudes aus den Laserdaten genutzt. Für die Interpretation wurden geometrische Klassen definiert. Die Klassifikation diente dann als Grundlage für die Korrektur der geometrischen Eigenschaften der Gebäudeoberflächen.

Die Ergebnisse in Kapitel 5 zeigen das Potential der integrierten Vorgehensweise. Folgende Aspekte werden deutlich:

- Die Repräsentation der Gebäude mit einer Polyedertopologie, abstrahiert von der Geometrie, ist als Repräsentationsstruktur für Gebäude geeignet. Wissen über Gebäude lässt sich auf allen Ebenen der Modellierung leicht integrieren.
- Die Verwendung lokalen Nachbarschaftswissens über Gebäudeteile kann zur Verbesserung der Gebäuderepräsentation beitragen.
- Die Unterscheidung der Gebäudetypen ist unter Verwendung ausschließlich lokalen Wissens möglich.
- Um nur die wichtigsten semantischen Eigenschaften von Gebäudeteilen zu erfassen, ist eine umfangreiche Modellierung notwendig.

### 6.2 Ausblick

In dieser Arbeit werden die wesentlichen Aspekte des Ansatzes zur integrierten Interpretation und Rekonstruktion behandelt. Ergänzungen und Erweiterungen sind sowohl auf konzeptioneller Ebene und vor allem auf der Ebene der Realisierung wünschenswert.

Der beschriebene Prozess behandelt einen Ausschnitt aus dem gesamten Prozess, der notwendig ist, um aus den Sensordaten Gebäude und Gebäudeteile in ihrer Funktion und Erscheinung abzuleiten:

- Die Ableitung einer symbolischen Gebäudebeschreibung aus Rasterdaten muss durch die Integration von gebäudespezifischem Wissen verbessert werden. Die symbolische Beschreibung könnte so verbessert werden und eine bessere Ausgangssituation für die Klassifikation und Interpretation bieten.
- Die rekonstruierte und interpretierte Näherungsoberfläche muss weiter zu vollständigen Gebäuden gruppiert werden. Das Ergebnis der Klassifikation des Gebäudetyps kann genutzt werden, um noch spezifischeres Modellwissen des erkannten Gebäudetyps dem Gebäude aufzuprägen. Ein verbessertes Klassifikationsergebnis ist zu erwarten.

Der beschriebene Interpretationsprozess ermöglicht eine Klassifikation der Elemente der Polyederdarstellung. Eine wichtige Erweiterung ist die Integration einer variablen Topologie. Da nicht sichergestellt ist, dass in der Vorverarbeitung eine Gebäudebeschreibung mit richtiger Gebäudetopologie gefunden wird, sollte der nachfolgende Interpretationsprozess falsche Topologien korrigieren können. Ein erster Schritt besteht darin, eine Zufallsvariable für die Ausrichtung von Kanten der Triangulation einzuführen und so das Flippen von Kanten zu erlauben. Da der Lösungsraum des Zufallsfeldes sich dadurch aber stark vergrößert, muss noch gezeigt werden, ob das im Moment verwandte Modellwissen noch ausreicht. Falls es sich um eine Triangulation handelt, lassen sich Ansätze der Bewertung von Kanten (s. z. B. FÖRSTNER 1999) für Gebäude adaptieren.

Grundsätzlich sollten auch andere Teile der topologischen Struktur der Oberflächenbeschreibung veränderbar sein (nach dem Split&Merge-Paradigma). Einzelne Kanten und Dreiecke sollten durch einen einzelnen Knoten ersetzt werden können oder einzelne Punkte sollten in Gruppen aufgesplittet werden können. Hier ist mit entsprechenden Problemen wie für das Berücksichtigen von Kantenrichtungen im vorhergehenden Absatz zu rechnen.

Die Korrekturfähigkeit des beschriebenen Ansatzes sollte durch die Verwendung eines hierarchischen Markoff-Zufallsfeldes verbessert werden (s. Abs. 1.4). Dazu ist eine hierarchische Modellierung der Gebäude notwendig. Hier ist zu prüfen, ob die bekannten Modellierungsformen der Gebäude auf unterschiedlichen Repräsentationsebenen (s. Abs. 1.2) verwendet werden können.

Bei der Verwendung der Daten unterschiedlicher Sensoren ist die Zuordnung der Datensätze zu dem Gebäudemodell notwendig, wenn die Zuordnung nicht bereits durch Orientierungen, wie z. B. bei Luftbildern üblich, bereits bekannt ist. Hier sind Matching-Verfahren notwendig, die entweder die topologische Gebäudebeschreibung den Daten zuordnen, oder die Zuordnungen zwischen den Daten unterschiedlicher Sensoren finden.

Die Strukturierung der Gebäudemodelle sollte erweitert werden. Wird nicht das gesamte Gebäude für die Klassifikation modelliert, sondern werden einzelne Gebäudeteile beschrieben, können weitere Aggregationsebenen in die Modellierung einbezogen werden. Hier lässt sich dann die Gebäudestrukturierung in End- und Verbindungsstücken von FISCHER *et al.* 1997 nutzen (s. Abb. 1.2). Die Modellierung von Gebäudeteilen würde die Interpretation und Rekonstruktion



Abbildung 6.1: Komplexe Gebäudegrundtypen: kombiniertes Flachdach- und Giebeldachhaus.

komplexer Gebäude, wie sie in Abbildung 6.1 gezeigt sind, erleichtern.

Die integrierte Interpretation und die Rekonstruktion ist in dieser Arbeit als iterativer Prozess entwickelt worden. Dabei wurde die Separierbarkeit der beiden Teilprozesse angenommen und empirisch nachgewiesen, um den Lösungsraum des Rekonstruktionsproblems einzuschränken. Da die

Rekonstruktion wie die Interpretation durch eine statistische Optimierung innerhalb der Bayes-Statistik beschreibbar ist, erscheint aus theoretischer Sicht auch eine gemeinsame Optimierung möglich. Die gemeinsame Optimierungsfunktion sollte untersucht werden, da durch einen gemeinsamen Ansatz eine stärkere Verzahnung des Klassifikationswissens und des Rekonstruktionswissens möglich ist.

Die Realisierung des Verfahrens erfolgt auf der Basis eines geometrischen Modells. Um eine aussagekräftigere Modellierung zu erreichen, sollte noch stärker semantische Information in das Modell eingebracht werden, wie in Abschnitt 3 beschrieben wurde. Die Entscheidung über die richtige semantische Modellierungsebene ist, wie sich im DFG-Projekt „Semantische Modellierung“ (FÖRSTNER UND PLÜMER 1999) gezeigt hat, nicht einfach zu finden. Zu viel wie auch zu wenig Semantik können den Interpretationsprozess behindern. Eine einzige Ebene der Modellierung wird daher nicht reichen. Es erscheint eine semantische hierarchische Modellierung notwendig. Hier bietet sich die Nutzung der Bayes-Netze (s. PEARL 1988 oder KOCH 2000, S. 157) an.

Durch die Hinzunahme von mehr semantischer Information ist eine bessere Korrekturfähigkeit der Näherungslösung durch das Verfahren zu erwarten. Das Einführen von weiteren Zufallsvariablen für die Kantenrichtungen und topologische Umgruppierung wird daher möglich.

Das Verfahren ist bisher für Laserscannerdaten (Digitale Oberflächenmodelle) und zwei Gebäudemodelle realisiert worden. Um zu einer abschließenden Beurteilung des Verfahrens zu kommen, bedarf es noch umfangreicher Tests, die eine breite Anzahl von Gebäudetypen enthalten. Ebenso kann die Allgemeinheit des Ansatzes erst durch die Verwendung unterschiedlicher Sensordaten (z. B. Luftbilder, terrestrische Aufnahmen, u. a.) demonstriert und nachgewiesen werden. Hierzu sind die angegebenen Likelihood-Funktionen Gl. 3.1.2 bis Gl. 3.1.4 zu präzisieren und zu realisieren.

Abschließend lässt sich festhalten, dass es sich bei dem vorgestellten Verfahren um eine Technik der Gebäuderekonstruktion, die weiter wissenschaftlich untersucht und ausgedehnt werden sollte.



# Anhang A

## Unsichere Repräsentationen und die Fortpflanzung von Kovarianzen

Grundlage dieser Arbeit ist die Beobachtung von Punkten auf Digitalen Oberflächenmodellen (DOM). Dabei besteht der Beobachtungsprozess aus der Selektion des Punktes und der Messung seiner Höhe. Beide Prozesse sind fehlerbehaftet, so dass das DOM als eine Beobachtung der realen Objektoberfläche angesehen werden muß. Aus den Punktbeobachtungen werden in dieser Arbeit komplexe geometrische Objekte abgeleitet, die somit in ihrer Existenz wie auch in ihrer Geometrie fehlerbehaftet sind.

In diesem Abschnitt werden deshalb die wesentlichen in der Arbeit verwandten statistischen Methoden beschrieben, die den Umgang mit unsicheren geometrischen Objekten ermöglichen.

### A.1 Das Fehlerfortpflanzungsgesetz

Die Basis der Propagation von Unsicherheiten bildet das Fehlerfortpflanzungsgesetz. Mit ihm ist es möglich, Unsicherheiten der Beobachtungen in geschätzte Parameter zu übertragen. Die Unsicherheiten seien durch Kovarianzmatrizen repräsentiert.

**Definition A.1 (Kovarianzmatrix)** *Es sei  $\mathbf{x}$  ein  $n \times 1$  Zufallsvektor, dann bezeichnet man*

$$D(\mathbf{x}) = ((\sigma_{ij})) = E((\mathbf{x} - E(\mathbf{x}))(\mathbf{x} - E(\mathbf{x}))^T)$$

*als Kovarianzmatrix oder Dispersionsmatrix.*

**Satz A.1 (Fehlerfortpflanzungsgesetz)** (KOCH 1997, S. 109) *Sei  $\mathbf{x}$  ein  $n \times 1$  Zufallsvektor mit der Kovarianzmatrix  $D(\mathbf{x})$  und  $\mathbf{A}$  eine feste  $m \times n$  Koeffizientenmatrix sowie  $\mathbf{b}$  ein  $m \times 1$  Vektor von Konstanten. Dann gilt für die Kovarianzmatrix des aus der linearen Transformation  $\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{b}$  sich ergebenden  $m \times 1$  Zufallsvektors  $\mathbf{y}$*

$$D(\mathbf{y}) = D(\mathbf{A}\mathbf{x} + \mathbf{b}) = \mathbf{A}D(\mathbf{x})\mathbf{A}^T.$$

Handelt es sich um eine nicht lineare Abbildung  $\mathbf{y} = f(\mathbf{x})$ , muß linearisiert werden. Die Koeffizientenmatrix  $\mathbf{A}$  wird dann zu

$$\mathbf{A} = \begin{pmatrix} \frac{\partial y_1}{\partial x_1} & \cdots & \frac{\partial y_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial y_m}{\partial x_1} & \cdots & \frac{\partial y_m}{\partial x_n} \end{pmatrix},$$

In den folgenden Abschnitten wird von Satz A.1 intensiv gebrauch gemacht.

## A.2 Repräsentation einfacher unsicherer geometrischer Objekte

### A.2.1 Punkte

Der Punkt wird im  $\mathbb{R}^2$  als

$$p(x, y) \quad \text{mit} \quad \Sigma_{pp} = \begin{pmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{pmatrix} \quad (\text{A.2.1})$$

mit dem Koordinatenpaar  $(x, y)$  und der vollen Kovarianzmatrix  $\Sigma_{pp}$  repräsentiert. Analog im  $\mathbb{R}^3$  gilt

$$p(x, y, z) \quad \text{mit} \quad \Sigma_{pp} = \begin{pmatrix} \sigma_x^2 & \sigma_{xy} & \sigma_{xz} \\ \sigma_{xy} & \sigma_y^2 & \sigma_{yz} \\ \sigma_{xz} & \sigma_{yz} & \sigma_z^2 \end{pmatrix}. \quad (\text{A.2.2})$$

Die Punktrepräsentation kann auch als Repräsentation des Ortsvektors der Punkte interpretiert werden.

### A.2.2 Geraden

Die Gerade im  $\mathbb{R}^2$  wird in der Regel in der Hesseschen Normalenform

$$x \cos \phi + y \sin \phi - d = 0 \quad \text{mit} \quad \Sigma_{ll} = \begin{pmatrix} \sigma_\phi^2 & \sigma_{\phi d} \\ \sigma_{\phi d} & \sigma_d^2 \end{pmatrix}$$

geschrieben. Ebenso ist die Verwendung der Repräsentation

$$ax + by - d = 0 \quad \text{für} \quad a^2 + b^2 = 1$$

$$\text{mit} \quad \Sigma_{ll} = \begin{pmatrix} \sigma_a^2 & \sigma_{ab} & \sigma_{ad} \\ \sigma_{ab} & \sigma_b^2 & \sigma_{bd} \\ \sigma_{ad} & \sigma_{bd} & \sigma_d^2 \end{pmatrix}$$

möglich. Die Achsenabschnittsform der Geradenrepräsentation

$$y = ax + b \quad \text{mit} \quad \Sigma_{ll} = \begin{pmatrix} \sigma_{aa}^2 & \sigma_{ab} \\ \sigma_{ab} & \sigma_b^2 \end{pmatrix} \quad (\text{A.2.3})$$

erlaubt keine Repräsentation von Geraden parallel zur  $y$ -Achse und wird daher in dieser Arbeit nicht weiter berücksichtigt.

FÖRSTNER 1992 schlägt eine redundanzfreie Repräsentation der Kovarianzmatrix vor, die hier jedoch außer Acht gelassen wird, da die Redundanz in der Repräsentation der Elemente der Kovarianzmatrix in dieser Arbeit nicht von Bedeutung ist. Der nicht volle Rang der Kovarianzmatrix muß berücksichtigt werden.

Im  $\mathbb{R}^3$  kann die Gerade als Schnitt zweier Ebenen dargestellt werden, wobei die beiden Ebenen senkrecht zu jeweils einer Koordinatenachse gewählt sind.

$$x = az + b \quad (\text{A.2.4a})$$

$$y = cz + d \quad (\text{A.2.4b})$$

Die Kovarianzmatrix der 4 notwendigen Parameter kann mit

$$\Sigma_E = \begin{pmatrix} \sigma_a^2 & \sigma_{ab} & \sigma_{ac} & \sigma_{ad} \\ \sigma_{ab} & \sigma_b^2 & \sigma_{bc} & \sigma_{bd} \\ \sigma_{ac} & \sigma_{bc} & \sigma_c^2 & \sigma_{cd} \\ \sigma_{ad} & \sigma_{bd} & \sigma_{cd} & \sigma_d^2 \end{pmatrix} \quad (\text{A.2.5})$$

geschrieben werden. Zu einer redundanzfreien Repräsentation der unsicheren Ebene wären nach FÖRSTNER 1992 nur 9 weitere Parameter zu den 4 Ebenenparameter, also 13 Parameter notwendig. Innerhalb dieser Arbeit ist jedoch eine redundanzfreie Repräsentation nicht notwendig und unterbleibt deswegen.



### A.2.3 Dreiecke in 3D

Dreiecke im dreidimensionalen Raum werden über die drei Eckpunkte repräsentiert. Die Verkantung ist im Gegensatz zu allgemeinen Polygonen eindeutig. Somit ist eine  $9 \times 9$  Kovarianzmatrix notwendig, die 45 weitere Parameter einführt, wenn alle Punktkoordinaten als unkorreliert anzunehmen sind.

### A.2.4 Richtungsvektoren

Im  $\mathbb{R}^2$  können Richtungsvektoren über das Azimut  $\tau$  oder den zum rechten Winkel komplementären Winkel  $\omega$  repräsentiert werden.

$$\mathbf{v} = \begin{pmatrix} \sin \tau \\ \cos \tau \end{pmatrix} = \begin{pmatrix} \cos \omega \\ \sin \omega \end{pmatrix} = \begin{pmatrix} a \\ b \end{pmatrix} \quad \text{mit} \quad \sigma_v = \begin{pmatrix} \sigma_a^2 & \sigma_{ab} \\ \sigma_{ab} & \sigma_b^2 \end{pmatrix}$$

In Abb. A.1 kann die Bedeutung der Winkel abgelesen werden.




Abbildung A.1: Richtungsvektor in  $\mathbb{R}^2$ . Die erste Komponente ist mit  $x$ , die zweite Komponente mit  $y$  bezeichnet.

Im  $\mathbb{R}^3$

$$\mathbf{v} = \begin{pmatrix} \cos \omega \sin \theta \\ \sin \omega \sin \theta \\ \cos \theta \end{pmatrix} = \begin{pmatrix} \cos \omega \cos \phi \\ \sin \omega \cos \phi \\ \sin \phi \end{pmatrix} = \begin{pmatrix} a \\ b \\ c \end{pmatrix} \quad \text{mit} \quad \sigma_v = \begin{pmatrix} \sigma_a^2 & \sigma_{ab} & \sigma_{ac} \\ \sigma_{ab} & \sigma_b^2 & \sigma_{bc} \\ \sigma_{ac} & \sigma_{bc} & \sigma_c^2 \end{pmatrix}$$

Die Bedeutung der Winkel im Falle von normierten Vektoren kann in Abb. A.2 ersehen werden.

Die Parametrisierung kann also mit zwei oder drei Parametern erfolgen. Im Falle von normierten Richtungsvektoren mit drei Parametern wird zusätzlich die Normierungsbedingung eingeführt. Damit liegt aber keine minimale Parameteranzahl mehr vor.

## A.3 Ableitung von Winkeln aus Richtungsvektoren

Ist die singuläre Kovarianzmatrix eines Richtungsvektors bekannt, können die Varianzen der entsprechenden Winkel ebenfalls über das FFG abgeleitet werden.

Die zugrundeliegenden Winkel der Repräsentation einer Richtung in 3D ergeben sich aus dem Richtungsvektor mit

$$\phi = \arcsin r_3 \quad \text{oder} \quad \theta = \arccos r_3 \tag{A.3.1}$$

$$\omega = \arccos \frac{r_1}{\cos \phi} \tag{A.3.2}$$




Abbildung A.2: Richtungsvektor im  $\mathbb{R}^3$ . Die Achsen des Koordinatensystems sind hier beispielhaft mit x,y und z bezeichnet.

Über das FFG folgt

$$\sigma_\phi = \sigma_\theta = \frac{1}{\sqrt{1-r_3}} \sigma_{r_3} \quad (\text{A.3.3})$$

$$\sigma_\omega^2 = \begin{cases} \left(\frac{1}{r_2}\right)^2 \sigma_{r_1}^2 + \left(\frac{r_1 \tan \phi}{r_2}\right)^2 \sigma_\phi^2 & \text{für } r_2 \neq 0 \\ \left(\frac{1}{r_1}\right)^2 \sigma_{r_2}^2 + \left(\frac{r_2 \tan \phi}{r_1}\right)^2 \sigma_\phi^2 & \text{für } r_1 \neq 0 \\ \text{nicht bestimmt} & \text{sonst} \end{cases} \quad (\text{A.3.4})$$

In 2D ergibt sich analog

$$\omega = \arccos r_1 \quad (\text{A.3.5})$$

$$\sigma_\omega = \frac{1}{\sqrt{1-r_1^2}} \sigma_{r_1} \quad (\text{A.3.6})$$

## A.4 Fehlerfortpflanzung für Vektoren

Es seien  $\mathbf{a}$  und  $\mathbf{b}$  zwei beliebige feste oder freie, fehlerbehaftete Vektoren mit den Kovarianzmatrizen  $D(\mathbf{a})$  und  $D(\mathbf{b})$ . Ihre Korrelation sei durch die Kovarianzmatrix  $C(\mathbf{a}, \mathbf{b})$  beschrieben. Im folgenden werden für Basisvektoroperationen die abgeleiteten Koavarianzvektoren angegeben.

**Addition und Subtraktion** Das FFG bei Addition oder Subtraktion: Seien  $\mathbf{a}$  und  $\mathbf{b}$  zwei Vektoren mit den Dispersionsmatrizen  $D(\mathbf{a})$  und  $D(\mathbf{b})$  im  $\mathbb{R}^n$ . Die Kovarianzmatrix der Differenz und der Summe der beiden Vektoren ergibt sich aus dem Fehlerfortpflanzungsgesetz zu

$$D(\mathbf{a} - \mathbf{b}) = D(\mathbf{a} + \mathbf{b}) = D(\mathbf{a}) + D(\mathbf{b})$$

Werden die Korrelationen  $C(\mathbf{a}, \mathbf{b})$  und  $C(\mathbf{b}, \mathbf{a})$  zwischen den beiden Vektoren  $\mathbf{a}$  und  $\mathbf{b}$  berücksichtigt, ergibt sich

$$D(\mathbf{a} - \mathbf{b}) = D(\mathbf{a}) - C(\mathbf{a}, \mathbf{b}) - C(\mathbf{b}, \mathbf{a}) + D(\mathbf{b}) \quad (\text{A.4.1})$$

$$D(\mathbf{a} + \mathbf{b}) = D(\mathbf{a}) + C(\mathbf{a}, \mathbf{b}) + C(\mathbf{b}, \mathbf{a}) + D(\mathbf{b}), \quad (\text{A.4.2})$$

d.h. für die Differenz (Summe) wird die Dispersionsmatrix zu groß (klein) geschätzt, wenn die Korrelationen positiv sind und sie unberechtigterweise vernachlässigt werden.

**Skalierung** FFG bei Skalierung: Sei  $\mathbf{a}$  ein Vektor und  $\lambda$  ein Skalierungsfaktor, dann gilt für die Kovarianzmatrix des skalierten Vektors

$$D(\lambda\mathbf{a}) = \lambda^2 D(\mathbf{a})$$

**Normierung** FFG bei Normierung als spezielle Form der Skalierung: Sei  $\mathbf{a}$  ein beliebiger Vektor, der normiert werden soll. Der normierte Vektor sei mit  $\bar{\mathbf{a}}$  bezeichnet. Die Normierung entspricht einer Skalierung. Daher folgt die Kovarianzmatrix des normierten Vektors zu

$$D(\bar{\mathbf{a}}) = \frac{1}{|\mathbf{a}|^2} D(\mathbf{a}),$$

wenn  $|\mathbf{a}|$  die Länge oder den Betrag des Vektors  $\mathbf{a}$  bezeichnet.

**Länge eines Vektors**

$$D(|\mathbf{a}|) = \frac{1}{|\mathbf{a}|^2} \mathbf{a}^t D(\mathbf{a}) \mathbf{a} \quad (\text{A.4.3})$$

**Vektorprodukt** FFG bei Vektorprodukt: Seien zwei Vektoren  $\mathbf{a}$  und  $\mathbf{b}$  mit den Kovarianzmatrizen  $D(\mathbf{a})$  und  $D(\mathbf{b})$  im  $\mathbb{R}^3$  gegeben. Das Vektorprodukt läßt sich mit den schiefsymmetrischen Matrizen  $\mathbf{S}_a$  und  $\mathbf{S}_b$  als<sup>1</sup>

$$\begin{aligned} \mathbf{c} &= \mathbf{a} \times \mathbf{b} = -\mathbf{b} \times \mathbf{a} \\ \mathbf{S}_a \mathbf{b} &= -\mathbf{S}_b \mathbf{a} \end{aligned}$$

schreiben. Damit liegen zwei in jeweils einem Vektor lineare Formulierungen des Vektorproduktes vor. Die Dispersionmatrix des Ergebnisvektors ergibt sich nach dem FFG zu

$$D(\mathbf{c}) = \mathbf{S}_b D(\mathbf{a}) \mathbf{S}_b^t - \mathbf{S}_a C(\mathbf{a}, \mathbf{b}) \mathbf{S}_b^t - \mathbf{S}_b C(\mathbf{b}, \mathbf{a}) \mathbf{S}_a^t + \mathbf{S}_a D(\mathbf{b}) \mathbf{S}_a^t.$$

Falls die beiden Vektoren unkorreliert sind, verschwindet der zweite und dritte Additionsterm auf der rechten Seite.

## A.5 Ebenen

Für die Oberflächenrekonstruktion von beliebigen Körpern ist die Repräsentation von Ebenen in beliebigen Lagen notwendig. Insbesondere stellen senkrechte Ebenen in der Rekonstruktion von 3D Stadtmodelle eine besondere Zielgröße dar, so dass Möglichkeit zur Repräsentation von vertikalen Ebenen zwingend notwendig ist. Deshalb wird im folgenden nur die Hessesche Normalenform weiter untersucht.

Die übliche Darstellung der Ebene in Hessescher Normalenform

$$\begin{pmatrix} n_1 \\ n_2 \\ n_3 \end{pmatrix} \mathbf{x} = d \quad (\text{A.5.1})$$

wird dazu weiter spezialisiert: bei dem orthogonalen Vektor soll es sich um einen Richtungsvektor in 3D handeln, der auf die Länge 1 normiert ist und in Polarkoordinaten beschrieben ist

$$x \cos \omega \sin \phi + y \sin \omega \sin \phi + z \cos \phi = d. \quad (\text{A.5.2})$$

<sup>1</sup>

$$\mathbf{S}_a = \begin{pmatrix} 0 & -a_3 & a_2 \\ a_3 & 0 & -a_1 \\ -a_2 & a_1 & 0 \end{pmatrix}$$

Das Vorzeichen des Abstandparameters ist durch die Parametrisierung nicht festgelegt. Mit einem Vorzeichenwechsel des Abstandes lassen sich die Vorzeichen aller Komponenten des Richtungsvektors ohne Aufwand ändern.

Spezielle Ebenen sind:

- Vertikale Ebenen:

$$\phi = \frac{\pi}{2} \text{ und } d, \omega \text{ fest} \quad (\text{A.5.3})$$

- Horizontale Ebenen:

$$\phi = 0, \quad d \text{ fest} \quad \text{und} \quad \omega = \text{beliebig} \quad (\text{A.5.4})$$

FÖRSTNER 1992 schlägt die Repräsentation der Ebene durch die Koordinaten des Durchstoßpunktes des im Ursprung des Koordinatensystems festgehaltenen Normalenvektor durch die Ebene vor.

$$x_o, y_o, z_o \quad (\text{A.5.5})$$

Die Analogie zur Hesseschen Normalenform ist offensichtlich, da die Richtung des Ortsvektors des Durchstoßpunktes  $(x_o, y_o, z_o)^t$  parallel zum Normalenvektor der Ebene liegt und die Länge des Ortsvektors der Abstand vom Koordinatenursprung ist. Daher lässt sich Repräsentation durch die Hessesche Normalenform wie folgt in die Repräsentation über Durchstoßpunkt transformieren.

$$\begin{pmatrix} x_o \\ y_o \\ z_o \end{pmatrix} := d \begin{pmatrix} a \\ b \\ c \end{pmatrix} \quad (\text{A.5.6})$$

$$D(x_o, y_o, z_o) = A^t D(a, b, c, d) A \quad (\text{A.5.7})$$

$$\text{mit } A = \begin{pmatrix} d & 0 & 0 \\ 0 & d & 0 \\ 0 & 0 & d \\ a & b & c \end{pmatrix} \quad (\text{A.5.8})$$

### A.5.1 Unsichere Ebenen

Liegen zur Bestimmung der Ebenen mehr als die minimale Anzahl von Punktbeobachtungen vor, kann eine ausgleichende Ebene bestimmt werden. Die geschätzten Parameter können dann mit Varianzen und Kovarianzen versehen werden. Diese können in zwei Formen repräsentiert werden. Die übliche Repräsentationsform ist eine Kovarianzmatrix, die Varianzen und Kovarianzen für die Repräsentation mit der minimalen Anzahl der Parameter der Hesseschen Normalenform enthält.

$$D\left(\begin{pmatrix} \omega \\ \phi \\ d \end{pmatrix}\right) = \begin{pmatrix} \sigma_\omega^2 & \sigma_{\omega\phi} & \sigma_{\omega d} \\ \sigma_{\omega\phi} & \sigma_\phi^2 & \sigma_{\phi d} \\ \sigma_{\phi d} & \sigma_{\omega d} & \sigma_d^2 \end{pmatrix} \quad (\text{A.5.9})$$

In dieser Arbeit werden die Parameter der Ebenen in den Normalenvektor und den Abstand aufgeteilt, da der Abstand für lokale Interpretationen bei angenommenen Schnitt nicht bedeutsam ist; d.h. eine Repräsentation mit einer singulären  $4 \times 4$  Kovarianzmatrix wird verwandt.

$$D_{EE} = \begin{pmatrix} \Sigma_{nn} & \Sigma_{nd} \\ \Sigma_{nd} & \sigma_d^2 \end{pmatrix} \quad (\text{A.5.10})$$

### A.5.2 Direkte Lösung

Da für die Berechnung der Näherungslösung der Ebenenparameter in der Kleinste-Quadrate-Schätzung die Berechnung von direkten Lösungen der Ebenengleichung notwendig sind, sollen hier kurz die üblichen Verfahren angegeben werden.

Seien 3 Punkte in allgemeiner Lage gegeben. Für die direkte Berechnung der Ebenenparameter  $\omega$ ,  $\phi$  und  $d$  bietet sich an, in  $P_1$  ein lokales Koordinatensystem zu definieren, das parallel zu dem globalen Koordinatensystem ist. Dann werden die beiden Richtungsvektoren von  $P_1$  auf  $P_2$  und  $P_3$  berechnet.

$$\mathbf{r}_i = \begin{pmatrix} dx_{1i} \\ dy_{1i} \\ dz_{1i} \end{pmatrix}, \quad \text{für } i \in 2, 3 \quad (\text{A.5.11})$$

Die Ebenennormale ergibt sich aus dem Spatprodukt der beiden Richtungsvektoren

$$\mathbf{n} = \mathbf{r}_2 \times \mathbf{r}_3. \quad (\text{A.5.12})$$

Der Abstand kann dann durch Einsetzen eines Punktes in Gl. A.5.2 berechnet werden.

### A.5.3 Mittelung von zwei Ebenennormalenvektoren

Es sei ein Punkt  $P$  gegeben, von dem bekannt ist, dass er auf mehreren Ebenen  $e_i$  liegt. Durch den Punkt ist der Abstand jeder Ebene zum Koordinatenursprung bestimmt, so dass für die Mittelung der Ebenen nur die Normalenvektoren betrachtet werden müssen. Falls die Orientierung der Ebenen nicht berücksichtigt werden muß, ergibt sich das Mittel zweier Vektoren zu

$$d\bar{\mathbf{n}} = \frac{1}{2} \min_{|d\bar{\mathbf{n}}|} (\mathbf{n}_1 - \mathbf{n}_2, \mathbf{n}_1 + \mathbf{n}_2) \quad (\text{A.5.13})$$

$$\bar{\mathbf{n}} = \mathbf{n}_1 + d\bar{\mathbf{n}} \quad (\text{A.5.14})$$

Bei der Berücksichtigung der Orientierung der Ebenen vereinfacht sich die Berechnung der Korrektur  $d\bar{\mathbf{n}}$  zu

$$\bar{\mathbf{n}} = \frac{1}{2}(\mathbf{n}_1 - \mathbf{n}_2). \quad (\text{A.5.15})$$

Abschließend ist in beiden Fällen noch eine erneute Normierung des mittleren Normalenvektors  $\bar{\mathbf{n}}$  notwendig.



# Anhang B

## Notationen und Legende

### B.1 Allgemeines

$a, b, c, \dots, \alpha, \beta, \dots$	Kleine fette Buchstaben sind Vektoren.
$A, B, C, \dots, \Sigma, \dots$	Große fette Buchstaben sind Matrizen.
	Alle anderen Buchstaben sind Skalare.

### B.2 Statistische Größen

#### B.2.1 Klassifikation

$s$	Knoten des Zufallsfeldes
$S$	Menge aller Knoten des Zufallsfeldes
$s_i$	Elementarereignisse
$g$	Index der Knoten des Zufallsfeldes (Nummerierung)
$t, \mathbf{t}$	Index(-vektor) des stochastischen Zufallsfeldes
$\mathbf{x}$	Zustandsvektor des physikalischen Gibbsfeldes
$BL$	Beschreibungslänge
$P(\cdot)$	Wahrscheinlichkeit eines Ereignisses
$P(\cdot \cdot)$	Bedingte Wahrscheinlichkeit

#### B.2.2 Parameterschätzung

$n$	Anzahl der Beobachtungen
$u$	Anzahl der unbekanntesten festen Parameter
$r$	Anzahl der Restriktionen
$f(\cdot) = \mathbf{0}$	Beobachtungsfunktion im GMM
$h(\cdot) = \mathbf{0}$	Restriktionsfunktion im GMR
$g(\cdot) = \mathbf{0}$	Beobachtungsfunktion im gemischten Modell
$\beta$	Vektor der unbekanntesten festen Parameter
$\mathbf{X}$	Koeffizientenmatrix der unbekanntesten Parameter
$\mathbf{Z}$	Koeffizientenmatrix der Zufallsparameter
$\mathbf{P}$	Gewichtsmatrix der Beobachtungen
$\mathbf{H}$	Koeffizientenmatrix der Restriktionen
$\mathbf{w}$	Absolutgliedvektor der Restriktionen
$\mathbf{y}$	Beobachtungsvektor
$\gamma$	Vektor der Zufallsparameter
$\lambda$	Vektor der Lagrange'schen Multiplikatoren
$\hat{\cdot}$	Geschätzte Parameter

$D(\cdot)$	Dispersionsmatrix
$\Sigma$	Kovarianzmatrix
$\sigma^2$	Varianz der Gewichtseinheit
$\Omega$	Quadratsumme der Residuen
$\eta, \eta$	Messrauschen

### B.3 Geometrische Größen

$x, y, z$	kartesische Koordinaten
$p(x, y), p(x, y, z)$	Punkt im kontinuierlichen 2D oder 3D
$p(x_i, y_i)$	Punkt im diskreten 2D
$R$	Nachbarschaftsradius
$z_x, z_y$	Gradienten in $x$ - und $y$ -Richtung
$\mathbf{n}, d$	Normalenvektor und Abstand zum Ursprung als Parametrisierung einer Ebene

### B.4 Topologische Größen

$V, \mathcal{V}$	Knoten (engl. <i>vertex</i> ), Menge von Knoten
$E, \mathcal{E}$	Ecke (engl. <i>edge</i> ), Menge von Ecken
$F, \mathcal{F}$	Fläche oder Dreieck (engl. <i>face</i> ), Menge von Flächen oder Dreiecken

### B.5 Legende zu den Abbildungen

In den 3D Abbildungen werden die folgenden Farbkodierungen verwandt:

- Punkte:
  - grün: Eckpunkte
  - rot: Kantenbruchpunkte
  - blau: Flächenpunkte
- Kanten:
  - blau: Bruchkanten
  - grün: Flächenkanten
- Dreiecke/Flächen:
  - blau: vertikale Flächen
  - pink: schräge Flächen
  - gelb: horizontale Flächen



# Anhang C

## Abkürzungsverzeichnis

### C.1 Klassen der Gebäudeteile

#### C.1.1 Semantisches Modell

DP	Dachflächenpunkt
WP	Wandflächenpunkt
BP	Bodenflächenpunkt
FKP	Firstkantenpunkt
GKP	Giebelkantenpunkt
TKP	Traufkantenpunkt
BKP	Bodenkantenpunkt
VKP	Verbindungskantenpunkt
TKP	Traufkanteneckpunkt
FEP	Firsteckpunkt
BEP	Bodeneckpunkt
VFP	Verbindungsfirstpunkt
VTP	Verbindungstraufkantenpunkt
DK	Dachflächenkante
WK	Wandflächenkante
BK	Bodenflächenkante
TK	Traufkante
GK	Giebelkante
FK	Firstkante
BK	Bodenkante
AGK	aufgehende Kante
VK	Verbindungskante
DF	Dachfläche
BF	Bodenfläche
WF	Wandfläche

#### C.1.2 Geometrisches Modell

FP	Flächenpunkt
KP	Bruchkantenpunkt
EP	Eckpunkt
BK	Bruchkante
FK	Flächenkante
H	horizontale Fläche
O	schräge Fläche

V vertikale Fläche

## C.2 Weitere Abkürzungen

ICM	Iterated-Conditional-Modes
MAP	Maximum-A-Posteriori-Schätzung
MRF	Markoff-Zufallsfeld
DOM	Digitalen Oberflächenmodell
CGM	Gekoppeltes Zufallsfeld
GMM	Gauss-Markoff-Modell
GMR	Gauss-Markoff-Modell mit Restriktionen
BL	Beschreibungslänge
MDL	Minimale Beschreibungslänge
# ·	Anzahl der ·

# Abbildungsverzeichnis

1.1	Möglichkeiten der Repräsentation von Oberflächen. . . . .	14
1.2	Prinzip der Laserscannermessung bei Annahme eines fächerförmig messenden Laserscanners. . . . .	16
1.3	Vereinfachtes Prinzip der Laserscannermessung. . . . .	17
1.4	Zwei Gebäudegrundtypen: Flachdach- und Walmdachhaus . . . . .	19
2.1	Datenstruktur für Kanten einer triangulierten Oberfläche . . . . .	23
2.2	Die Topologie einer Würfeloberfläche kann in acht 0-Zellen (Würfecken), zwölf 1-Zellen (Würfelkanten) und sechs 2-Zellen (Würfelflächen) zerlegt werden (JÄNICH 1994, S. 117). . . . .	24
3.1	Visualisierung der Geometrie und Topologie des Walmdachhauses. (FEP=Firsteckpunkt, TEP=Traufeckpunkt, BEP=Bodeneckpunkt) . . . . .	38
3.2	Relation der abstrakten Objektrepräsentation zur Semantik und den geometrischen und radiometrischen Ausprägungen. . . . .	40
3.3	Komplexes Walmdachhaus mit Verbindungsknoten und Verbindungskanten. . . . .	41
3.4	Nachbarschaftsstruktur des Knotens. . . . .	42
3.5	Nachbarschaftsstruktur der Kante. . . . .	42
3.6	Nachbarschaftsstruktur der Fläche. . . . .	43
3.7	Darstellung aller Cliquentypen in der Nachbarschaft von Punkten bis zur vierten Ordnung: a) 1. Ordnung, b) 2. Ordnung, c) 3. Ordnung, d) 4. Ordnung. . . . .	43
3.8	Nachbarschaften auf einem Polyeder für Punkte, Kanten und Flächen . . . . .	44
3.9	Generelles Konzept der Gebäudeinterpretation: Aus einer Näherungsrepräsentation wird ein polymorpher Graph abgeleitet. Unter Verwendung unterschiedlicher Datenquellen und statistischen Wissens wird ein polymorphes Zufallfeld generiert. Die Realisierung des Feldes wird optimiert. . . . .	46
3.10	Überblick über den Auswerteprozess. . . . .	48
4.1	Nachbarschaftsdefinition auf der triangulierten Polyederoberfläche. Diese Abbildung ist eine Spezialisierung der Abbildung 3.8. . . . .	52
4.2	Satz von Häufigkeiten, die für jedes Gebäudemodell aus den repräsentativen Datensätzen abgeleitet werden. Für die Wertebereiche der Belegungen der Zufallsvariablen siehe die Gleichungen 4.1.1 bis 4.1.5. . . . .	54
4.3	Satz von bedingten Wahrscheinlichkeiten, die für jedes Gebäudemodell definiert oder gelernt werden müssen. Für die Wertebereiche der Belegungen der Zufallsvariablen siehe die Gleichungen 4.1.1 bis 4.1.5. . . . .	54
4.4	Ausgewählte Repräsentation einer Oberfläche eines Flachdachhauses. . . . .	54
4.5	Modellhäufigkeiten für ein viereckiges Flachdachgebäude. . . . .	55
4.6	Modellhäufigkeiten für ein Walmdachgebäude. . . . .	56
4.7	Ausgewählte Repräsentation der Oberfläche eines Walmdachhauses. . . . .	56
4.8	Modellwahrscheinlichkeiten für ein viereckiges Flachdachgebäude. . . . .	57
4.9	Modellwahrscheinlichkeiten für ein Walmdachgebäude. . . . .	57

4.10	Richtungsklassen: Die drei Richtungsklassen decken den ersten Quadranten vollständig ab. (H=horizontal,O=schräg,V=vertikal) . . . . .	64
5.1	Übersicht über die Tests auf dem synthetischen Datensatz. . . . .	69
5.2	Synthetischer Datensatz "Bungalow": (zeilenweise) 1) synthetisches Raster DOM, 2+3) Gradienten in erodierten DOMs in Zeilen und Spalten, 4+5) Gradienten des dilatierten DOMs in Zeilen und Spalten, 6) FEX-Ergebnis auf Gradienten des erodierten DOMs, 7) FEX-Ergebnis auf Gradienten des dilatierten DOMs, 8) Näherungsoberfläche 9) Übersicht der Abbildung . . . . .	70
5.3	Synthetischer Datensatz (Variante a und b): a priori Klassifikation. Die Legende ist in Anhang B.5 zu finden. . . . .	71
5.4	Synthetischer Datensatz (Variante a): rekonstruiertes Gebäude. . . . .	72
5.5	Synthetischer Datensatz (Variante a): Transformierte posteriori Chancen in der Klassifikation in Abhängigkeit der Klassifikation (0=FP, 1=KP, 2=EP, 3=FK, 4=BK, 5=H, 6=V) . . . . .	72
5.6	Synthetischer Datensatz (Variante b): Klassifikation nach 500 Iterationen . . . . .	73
5.7	Verlauf der diskreten Temperatur für den Metropolis-Algorithmus mit $T_o = 10.0$ . . . . .	73
5.8	Synthetischer Datensatz (Variante b): Transformierte posteriori Chancen in der ersten Klassifikation in Abhängigkeit der Klassifikation. (0=FP, 1=KP, 2=EP, 3=FK, 4=BK, 5=H, 6=V) . . . . .	74
5.9	Synthetischer Datensatz (Variante b): rekonstruiertes Gebäude . . . . .	74
5.10	Synthetischer Datensatz (Variante c): a priori Klassifikation: Fünf Knoten sind falsch klassifiziert worden. Die Fehlklassifikationen passen semantisch nicht zu den Klassifikationen in der Nachbarschaft. . . . .	75
5.11	Synthetischer Datensatz (Variante c): Klassifikation nach 100 Iterationen: Die Klassifikationen sind alle semantisch sinnvoll. Dennoch sind die aufgehenden Kanten und einige Eckpunkte falsch klassifiziert, was aber nur ein globales Verfahren feststellen könnte. . . . .	76
5.12	Synthetischer Datensatz (Variante c): Rekonstruiertes Gebäude . . . . .	77
5.13	Synthetischer Datensatz (Variante c): Transformierte posteriori Chancen der Klassifikation im ersten (links) und zweiten (rechts) globalen Iterationsschritt in Abhängigkeit der Klassifikation (0=FP, 1=KP, 2=EP, 3=FK, 4=BK, 5=H, 6=V, 7=O) . . . . .	77
5.14	Realer Datensatz "Block1": (zeilenweise) RasterDOM, Gradienten in erodierten DOMs in Zeilen und Spalten, Gradienten des dilatierten DOMs in Zeilen und Spalten, FEX-Ergebnis auf Gradienten des erodierten DOMs, FEX-Ergebnis auf Gradienten des dilatierten DOMs, Näherungsoberfläche mit Höhenschwellwert 449.0m und gesetzter Grundhöhe von 440.0m, editierte Näherungsoberfläche . . . . .	79
5.15	A priori Klassifikation der Simplizes der Triangulation ohne Berücksichtigung einer Umgebungshöhe und einer Segmentierung. . . . .	80
5.16	A priori Klassifikation der Simplizes der Triangulation (mit einer Umgebungshöhe von 440m und einem Höhenschwellwert von 449m). . . . .	81
5.17	Realer Datensatz (Variante a): ICM-Algorithmus, Abbruch bei keinen Klassifikationsänderungen und Summe der Punktbewegungen unterhalb von 1.0 m, Gebäudemodell "Bungalow" . . . . .	82
5.18	Realer Datensatz (Variante a): Ergebnis ohne redundante Bruchkantenpunkte, Flächenpunkte und Flächenkanten. . . . .	83
5.19	Realer Datensatz (Variante a): Verlauf der Anzahl der Änderungen der Klassifikation und der Gesamtwahrscheinlichkeit in den Klassifikationsiterationen. . . . .	84
5.20	Realer Datensatz (Variante b): Rekonstruktionsergebnis nach der dritten und gleichzeitig letzten geometrischen Iteration. . . . .	85
5.21	Realer Datensatz (Variante b): Verlauf der Anzahl der Änderungen der Klassifikation und der Gesamtwahrscheinlichkeit in den ersten Klassifikationsiterationen. . . . .	86

5.22 Realer Datensatz (Variante b): Verlauf der Anzahl der Änderungen der Klassifikation (links) und der Gesamtwahrscheinlichkeit in den zweiten Klassifikationsiterationen (rechts). . . . .	86
5.23 Realer Datensatz (Variante b): Verlauf der Anzahl der Änderungen der Klassifikation (links) und der Gesamtwahrscheinlichkeit in den dritten Klassifikationsiterationen (rechts). . . . .	86
5.24 Realer Datensatz (Variante c): Ergebnis der integrierten Interpretation und Rekonstruktion. . . . .	87
5.25 Realer Datensatz (Variante d): Ergebnis der Klassifikation und Rekonstruktion. . .	88
5.26 Realer Datensatz (Variante d): Verlauf der Anzahl der Änderungen der Klassifikationen (rechts) und der Gesamtwahrscheinlichkeit in den Klassifikationsiterationen (rechts). Die Gesamtwahrscheinlichkeiten liegen alle unterhalb von $10^{-4}$ . . . . .	89
6.1 Komplexe Gebäudegrundtypen: kombiniertes Flachdach- und Giebeldachhaus. . . .	92
A.1 Richtungsvektor in $\mathbb{R}^2$ . Die erste Komponente ist mit $x$ , die zweite Komponente mit $y$ bezeichnet. . . . .	97
A.2 Richtungsvektor im $\mathbb{R}^3$ . Die Achsen des Koordinatensystems sind hier beispielhaft mit $x, y$ und $z$ bezeichnet. . . . .	98



# Literatur

- ACKERMANN, F. (1999): Airborne laser scanning – present status and future expectations. *ISPRS Journal of Photogrammetry & Remote Sensing*, 54:64–67.
- AVERDUNG, C.; LUTTERBACH, D. (1995): Automationsgestützte Organisation von Planungsverfahren. *Nachrichten aus dem Karten- und Vermessungswesen*, 1(117).
- AXELSSON, P.; PETZOLD, B. (1999): OEEPE Project on Laser Data Acquisition– Preliminary Report. Technischer Bericht, European Organisation for Experimental Photogrammetric Research.
- AXELSSON, P.; STERNER, H. (1999): Mapping Electrical Power lines with Laser Scanning. *GIM International*, (3):71–73.
- BALTSAVIAS, E.; KÄSER, C. (1999): DTM and orthoimage generation - a thorough analysis and comparison of four digital photogrammetric systems. In: *International Archives of Photogrammetry and Remote Sensing*, Band 32, Part 4.
- BESAG, J.E. (1986): On the statistical analysis of dirty pictures. *Journal of the Royal Statistical Society*, B 48:259–302.
- BLAKE, A. (1989): Comparison of the Efficiency of Deterministic and Stochastic Algorithms for Visual Reconstruction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(1):2–12.
- BOLLWEG, A. E. (1999): Water Management of the River Rhine. *GIM International*, Seiten 30–33.
- BRUNN, A.; WEIDNER, U. (1998): Hierarchical Bayesian nets for building extraction using dense digital surface models. *JPRS*, 53(5):296–307.
- BRUNN, A. (2000): Analyse von Laserscannerdaten zur Gebäuderekonstruktion. *Zeitschrift für Photogrammetrie, Fernerkundung und Geoinformationssysteme*, (3):189–190.
- BRUNN, A. (2000): A step towards semantic-based Building Reconstruction Using Markov-Random-Fields. In: *ISPRS Congress, Amsterdam*.
- BUSCH, A. (1992): *Bayes-Statistik und Markoff-Felder für die Restaurierung digitaler Bilder*, Band 396 der Reihe Reihe C. Deutsche Geodätische Kommission, Bayer. Akademie der Wissenschaften, Frankfurt am Main.
- DELINGETTE, H. (1999): General Object Reconstruction Based on Simplex Meshes. *International Journal of Computer Vision*, 32(2):111–146.
- DOCARMO, M. P. (1993): *Differentialgeometrie von Kurven und Flächen*. Vieweg, Braunschweig.
- DOLD, A. (1972): *Lectures on Algebraic Topology*. Springer, Berlin.
- EDELSBRUNNER, H. (1987): *Algorithms in Combinatorial Geometry*, Band 10 der Reihe EATCS Monographs on Theoretical Computer Science. Springer-Verlag, Berlin.
- ENGLERT, R.; CREMERS, A. B. (1997): Improving reconstruction of man-made objects from sensor images by machine learning. In: D. M. MCKEOWN, JR.; MCCCLONE, J. C.; JAMET, O. (Hrsg.), *Integrating Photogrammetric Techniques with Scene Analysis and Machine Vision III*, Band 3072 der Reihe Proceedings of SPIE, Seiten 263–274.
- ENGLERT, R.; GÜLCH, E. (1996): One-Eye Stereo System for the Acquisition of Complex 3D Building Descriptions. *GIS*, 9(4):16–21.

- ENGLERT, R. (1997): Systematic Acquisition of Generic 3D Building Model Knowledge. In: W. FÖRSTNER, L. PLÜMER (Hrsg.), *SMATI '97, Workshop on Semantic Modeling for the Acquisition of Topographic Information from Images and Maps*. Birkhäuser.
- FISCHER, A.; KOLBE, T.H.; LANG, F. (1997): Integration of 2D and 3D Reasoning for Building Reconstruction Using a Generic Hierarchical Model. In: W. FÖRSTNER, L. PLÜMER (Hrsg.), *SMATI '97, Workshop on Semantic Modeling for the Acquisition of Topographic Information from Images and Maps*. Birkhäuser.
- FISCHER, A.; KOLBE, T. H.; LANG, F.; CREMERS, A. B.; FÖRSTNER, W.; PLÜMER, L.; STEINHAGE, V. (1998): Extracting Buildings from Aerial Images Using Hierarchical Aggregation in 2D and 3D. *Computer Vision and Image Understanding*, 72(2).
- FISCHER, A.; KOLBE, T. H.; LANG, F. (1999): On the Use of Geometric and Semantic Models for Component-Based Building Reconstruction. In: *SMATI 99*, Seiten 101–120.
- FISCHLER, M. A.; BOLLES, R. C. (1981): Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Commision ACM*, 24:381–395.
- FÖRSTNER, W.; GÜLCH, E. (1997): Automatic Orientation and Recognition in Highly Structured Scenes. In: *Proceedings of SPIE Annual Meeting 1997*. SPIE.
- FÖRSTNER, W.; PLÜMER, L. (Hrsg.) (1999): *Workshop on Semantic modeling for the Acquisition of Topographic Information from Images and Maps*. URL: <http://www.tnt.uni-hannover.de~brueckner/smat199>.
- FÖRSTNER, W. (1992): Uncertain Spatial Relationships and their Use for Object Location in Digital Images. In: FÖRSTNER, W.; HARALICK, R. M.; RADIG, B. (Hrsg.), *Robust Computer Vision - Tutorial Notes*. Institut für Photogrammetrie, Universität Bonn.
- FÖRSTNER, W. (1999): Uncertain Neighborhood Relations of Point Sets and Fuzzy Delaunay Triangulation. In: *DAGM 1999*, LNCS. Springer.
- FUCHS, C.; LANG, F.; FÖRSTNER, W. (1994): On the Noise and Scale Behaviour of Relational Descriptions. In: EBNER; HEIPKE; EDER (Hrsg.), *ISPRS Vol. 30, 3/2*, Seiten 257–267. SPIE.
- FUCHS, C. (1998): *Extraktion polymorpher Bildstrukturen und ihre topologische und geometrische Gruppierung*. Deutsche Geodätische Kommission, Bayer. Akademie der Wissenschaften, Reihe C, Heft 502, Munich.
- GEIGER, D.; YUILLE, A. (1990): A Common Framework for Image Segmentation. *International Journal of Computer Vision*, 5(3):227–243.
- GEMAN, S.; GEMAN, D. (1984): Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. *Visual System Architectures*, Seiten 564–584.
- GÜLCH, E.; MÜLLER, H.; LÄBE, TH. (1999): Integration of automatic processes into semi-automatic building extraction. In: *Automatic Extraction of GIS Objects from Digital Imagery*, Band 32, Part 3-2W5. IAPRS.
- GÜLCH, E.; MÜLLER, H. (1998): Virtuelle Städte aus digitalen Bildern. In: *Workshop Virtual GIS, Rostock*.
- GÜNSEL, B.; JAIN, A. K.; PANAYIRCI, E. (1996): Reconstruction and Boundary Detection of Range and Intensity Images Using Multiscale MRF Representations. *Journal for Computer Vision and Image Understanding*, 63(2):353–366.
- HAALA, N.; ANDERS, K.-H. (1997): Acquisition of 3D urban models by analysis of aerial images, digital surface models, and existing 2D building information. In: D. M. MCKEOWN, JR.; MCCLOONE, J. C.; JAMET, O. (Hrsg.), *Integrating Photogrammetric Techniques with Scene Analysis and Machine Vision III*, Band 3072 der Reihe Proceedings of SPIE, Seiten 212–222.
- HAALA, N.; BRENNER, C. (1997): Interpretation of Urban Surface Models using 2D Building Information. In: GRUEN, A.; BALTSAVIAS, E.P.; HENRICSSON, O. (Hrsg.), *Automatic Extraction of Man-Made Objects from Aerial and Space Images (II)*, Seiten 213–223. Birkhäuser Verlag, Basel, Switzerland.



- HAALA, N. (1996): *Gebäuderekonstruktion durch Kombination von Bild- und Höhendaten*. Dissertation, Deutsche Geodätische Kommission, München, Vol. C 460.
- HELLWICH, O. (1997): *Linienextraktion aus SAR-Bildern mit einem Markoff-Zufallsfeld-Modell*. Dissertation, Technische Universität München.
- HENDRICKX, M.; VANDEKERCKHOVE, J.; FRERE, D.; MOONS, T.; GOOL, L. VAN (1997): On the 3D Reconstruction of House Roofs from Aerial Images of Urban Areas. *Proceedings Joint ISRPS Commission III/IV Workshop, Stuttgart, September*.
- HENRICSSON, O. (1995): Inferring Homogeneous Regions from Rich Image Attributes. In: GRUEN, A.; KUEBLER, O.; AGOURIS, P. (Hrsg.), *Automatic Extraction of Man-Made Objects from Aerial and Space Images*, Seite 13. Birkhäuser Verlag, Basel, Switzerland.
- HERMAN, M.; KANADE, T. (1987): The 3D MOSAIC Scene Understanding System: Incremental Recognition of 3D Scenes from Complex Images. In: FISCHLER/FIRSCHEIN (Hrsg.), *Readings in Computer Vision*, Seiten 471–482. Kaufmann.
- HOSS, H. (1997): Einsatz des Laserscanner-Verfahrens beim Aufbau des Digitalen Geländemodells (DGM) in Baden-Württemberg. *Photogrammetrie, Fernerkundung, Geoinformation*, (1):29–40.
- HUBER, P. J. (1981): *Robust Statistics*. Wiley NY.
- HUERTAS, A.; NEVATIA, R. (1988): Detecting Buildings in Aerial Images. *CVGIP: Image Understanding*, 41:131–152.
- HUG, C.; WEHR, A. (1997): Detecting and identifying topographic objects in image laser altimeter data. In: *3D Reconstruction and Modeling of Topographic Objects*, Band 32, Seiten 19–26. IAPRS.
- JÄNICH, K. (1994): *Topologie*. Springer, Berlin, 4. Auflage.
- JAYNES, C. O.; HANSON, A.; RISEMAN, E.; SCHULTZ, H. (1997): Building Reconstruction from Optical and Range Images. In: *CVPR '97*, Seiten 380–386. SPIE, IEEE Computer Society Press.
- JAYNES, CHRISTOPHER O.; HANSON, ALLEN; RISEMAN, EDWARD (1997): Model-Based Surface Recovery of Buildings in Optical and Ranges Images. In: *Semantic Modeling for the Acquisition of Topographic Information from Images and Maps*, Seiten 211–227.
- KATO, Z.; ZERUBIA, J.; BERTHOD, M. (1995): Unsupervised Parallel Image Classification Using a Hierarchical Markovian Model. In: *Fifth International Conference on Computer Vision (ICCV'95)*, Seiten 169–174.
- KIM, I. Y.; YANG, H. S. (1996): An Integration Scheme for Image Segmentation and Labeling Based on Markov Random Fields. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 18(1):69–73.
- KINDERMANN, R.; SNELL, J. L. (1994): *Markov Random Fields and Their Applications*. Contemporary Mathematics 1. American Mathematical Society.
- KLONOWSKI, J.; KOCH, K. R. (1997): Two Level Image Interpretation Based on Markov Random Fields. In: FÖRSTNER, W.; PLÜMER, L. (Hrsg.), *Semantic Modeling for the Acquisition of Topographic Information from Images and Maps: SMATI97*, Basel, Switzerland. Birkhäuser Verlag.
- KLONOWSKY, J. (1999): *Segmentierung und Interpretation digitaler Bilder mit Markoff-Zufallsfeldern*. Number 492 in C. Deutsche Geodätische Kommission.
- KNABENSCHUH, M.; PETZOLD, B. (1999): Data post-processing of Laser Scan Data for country-wide DTM production. In: FRITSCH, D.; HOBBIE, D. (Hrsg.), *Photogrammetric Week '99*, Seiten 233–240, Heidelberg. Wichmann Verlag.
- KOCH, K.R.; SCHMIDT, M. (1994): *Deterministische und stochastische Signale*. Dümmler Bonn.
- KOCH, K. R. (1990): *Bayesian Inference with Geodetic Applications*. Lecture Notes in Earth Sciences. Springer.

- KOCH, K.R. (1995): Markov random fields for image interpretation. *Zeitschrift für Photogrammetrie und Fernerkundung*, 63:84–90.
- KOCH, K. R. (1997): *Parameterschätzung und Hypothesentests in linearen Modellen*. Dümmler Verlag, 3. Auflage.
- KOCH, K.R. (2000): *Einführung in die Bayes-Statistik*. Springer Verlag.
- KOLBE, T.H.; PLÜMER, L.; CREMERS, A. B (1999): Identification of Buildings in Aerial Images Using Constraint Relaxation and Variable Elimination. *IEEE Intelligent Systems*. to appear.
- KOLLNIG, H.; NAGEL, H.-H. (1997): 3D pose Estimation by Directly matching Polyhedral Models to Gray Value Gradients. *International Journal of Computer Vision*, 23(3):283–302.
- KÖSTER, M. (1995): *Kontextsensitive Bildinterpretation mit Markoff-Zufallsfeldern*. Dissertation, Institut für Theoretische Geodäsie, Universität Bonn.
- KRAUS, K.; RIEGER, W. (1999): Processing of laser scanning data for wooded areas. In: FRITSCH, D.; HOBBIE, D. (Hrsg.), *Photogrammetric Week '99*, Seiten 221–231, Heidelberg. Wichmann Verlag.
- KRZYTEK, P. (1991): Fully Automatic Measurement of Digital Elevation Models. In: *Proceedings of the 43rd Photogrammetric Week, Stuttgart*, Seiten 203–214.
- KULSCHEWSKI, K. (1999): *Modellierung von Unsicherheiten in dynamischen Bayes-Netzen zur qualitativen Gebäudeerkennung*. Shaker-Verlag.
- LANG, F.; SCHICKLER, W. (1993): Semiautomatische 3D-Gebäudeerfassung aus digitalen Bildern. *Zeitschrift für Photogrammetrie und Fernerkundung*, 5:193–200.
- LANG, F. (1999): *Automatische Geometrische und Semantische Rekonstruktion von Gebäuden aus Bildern durch Ableitung von 3D-Gebäudeecken und deren 3D-Aggregation*. Dissertation, Institut für Photogrammetrie der Universität Bonn.
- LI, S.Z. (1995): *Markov Random Field Modeling in Computer Vision*. Springer-Verlag Tokyo.
- LÖCHERBACH, T. (1996): *Fusing Raster- and Vector-Data with Applications in Land-Use Mapping*. Deutsche Geodätische Kommission, Reihe C, No. 474, Munich.
- LOHR, U.; EIBERT, M. (1995): The TopoSys Laser Scanner System. In: FRITSCH, D.; HOBBIE, D. (Hrsg.), *Photogrammetric Week*, Seiten 263–267. Wichmann, Karlsruhe.
- LOHR, U.; SCHALLER, J. (1999): Trassenbefliegungen mit dem TopoSys Laserscanner. *Geoinformationssysteme*, (2):3–5.
- LOHR, U. (1998): Laserscan DEM for various applications. In: *GIS-Between Visions and Applications*, Band 32, Part. IAPRS.
- MAAS, H.-G. (1999): Fast determination of parametric house models from dense airborne laser-scanner data. In: *ISPRS Workshop on Mobile Mapping Technology*, Bangkok, Thailand.
- MASON, S.; BALTSAVIAS, M.; STALLMANN, D. (1994): High Precision Photogrammetric Data Set for Building Reconstruction and Terrain Modelling. ETH Zürich.
- MAYER, H. (1999): Automatic Object Extraction from Aerial Imagery – A Survey Focussing on Buildings. *Computer Vision and Image Understanding*, 74(2):138–149.
- MCCLURE, D. E. (1981): Image Models in Pattern Theory. In: ROSENFELD, AZRIEL (Hrsg.), *Image Modeling*, Seiten 259–275.
- METROPOLIS, N.; ROSENBLUTH, A.W.; ROSENBLUTH, M.L.; TELLER, A.H.; TELLER, E. (1953): Equation of state calculations by fast computing machines. *Journal of Chemistry and Physics*, 21:1987–1092.
- MIGNOTTE, M.; COLLET, C.; PÉREZ, P.; BOUTHEMY, P. (1997): Unsupervised hierarchical Markovian segmentation of sonar images. In: *4th IEEE Int. Conf. Image Processing (ICIP'97), Santa-Barbara, California*.
- MODESTINO, J. W.; ZHANG, J. (1991): A Markov Random Field Model-Based Approach to Image Interpretation. In: CHELLAPPA, R. RAMA; JAIN, ANIL (Hrsg.), *Markov Random Fields, Theory and Application*, Seiten 369–408. Academic Press, Boston.

- MOONS, TH.; FRERE, D.; VANDEKERCKHOVE, J.; GOOL, L. VAN (1998): Automatic Modelling and 3D Reconstruction of Urban House Roofs from High Resolution Aerial Imagery. *Computer Vision – ECCV’98, Freiburg*, Seiten 410–425.
- MÜLLER, K.P.; WÖLPERT, H. (1976): *Anschauliche Topologie*. Teubner Stuttgart.
- MÜLLER, H. (1998): Object-oriented modeling for the extraction of geometry, texture and reflectance from digital images. In: *Proceedings*, International Archives of Photogrammetry and Remote Sensing. ISPRS Commission IV Symposium, Stuttgart, September 6-10.
- PEARL, J. (1988): *Probabilistic Reasoning in Intelligent Systems*. Morgan Kaufmann Publishers.
- PREPARATA, F. P.; SHAMOS, M. I. (1985): *Computational Geometry*. Springer.
- RISSANEN, I. (1987): Minimum Description Length Principle. *Encyclopedia of Statistical Sciences*.
- ROUSSEEUW, P. J.; LEROY, A. M. (1987): *Robust Regression and Outlier Detection*. Wiley NY.
- ROUX, M.; MAÎTRE, H.; GIRARD, S. (1997): A Step Towards Stereo Reconstruction of Urban Aerial Images. In: *3D Reconstruction and Modeling of Topographic Objects*, Band 32. IAPRS.
- SCHMID, C.; ZISSERMAN, A. (1997): Automatic line matching across views. *Proceedings Conference on Computer Vision and Pattern Recognition, Puerto Rico*, Seiten 666–671.
- SEYFERT, E. (1995): Erste Erfahrungen bei der automatischen Generierung von digitalen Höhenmodellen in Siedlungsgebieten. In: FRITSCH, D.; HOBBIÉ, D. (Hrsg.), *Photogrammetric Week ’95*, Seiten 269–276, Heidelberg. Wichmann Verlag.
- STEINHAGE, V. (1999): Zur automatischen Gebäuderekonstruktion aus Luftbildern. Habilitationsschrift.
- STILLA, U.; GEIBEL, R.; JURKIEWICZ, K. (1997): Building Reconstruction using different views and context knowledge. In: *3D Reconstruction and Modeling of Topographic Objects*, Band 32, Seiten 129–136. IAPRS.
- SZELISKI, R. (1989): *Bayesian Modeling of Uncertainty in Low-Level Vision*. Kluwer Academic.
- TORR, P. H. S. (1997): An Assessment of Information Criteria for Motion Model Selection. In: *Proceedings CVPR*, Seiten 47–52.
- TUPIN, F.; MAÎTRE, H.; NOCILAS, J. F.; PECHERSKY, E. (1998): Linear feature detection on SAR images: application to the road network. *IEEE Transactions on Geoscience & Remote Sensing*, 36(2).
- VAN DAMME, R.; ALBOUL, L. (1997): Tight triangulation. Technischer Bericht, Faculty of mathematical Sciences, University of Twente, Enschede, Niederlande. URL: <http://www.math.utwente.nl/~vandamme/Trian/ulvik.html>.
- VON HANSEN, W.; VÖGTLE, TH. (1999): Extraktion der Geländeoberfläche aus flugzeuggetragenen Laserscanner-Aufnahmen. *Photogrammetrie, Fernerkundung, Geoinformation*, (4):229–236.
- VOSELMAN, G. (1992): *Relational Matching*. Lecture Notes in Computer Science 628. Springer-Verlag, Berlin.
- VOSELMANN, G. (1999): Building Reconstruction Using Planar Faces in Very High Density Height Data. In: *Automatic Extraction of GIS objects from Digital Imagery*. ISPRS.
- WALKER, E. L.; HERMAN, M.; KANADE, T. (1990): *A Framework for Representing and Reasoning about Three-Dimensional Objects for Vision*, Band 2 der Reihe Advances in Spatial Reasoning, Kapitel 6, Seiten 219–247. Ablex Publishing, Norwood, New Jersey.
- WANG, J. (1997): Image Segmentation via Energy Minimization on Partitions with Connected Components. In: PELILLO, M.; HANCOCK, E. R. (Hrsg.), *Energy Minimization Methods in Computer Vision and Pattern Recognition*, Seiten 101–116. Springer.
- WEHR, A.; LOHR, U. (1999): Airborne laser scanning – an introduction and overview. *ISPRS Journal of Photogrammetry & Remote Sensing*, 54:68–82.
- WEIDNER, U. (1995): Building Extraction from Digital Elevation Models. Technischer Bericht, Institut für Photogrammetrie, Bonn.

- WEIDNER, U. (1997): *Gebäudeerfassung aus Digitalen Oberflächenmodellen*. Deutsche Geodätische Kommission, Reihe C, No. 474, Munich.
- WEVER, C. (1999): Laserscannermessungen– ein Verfahren setzt sich durch. *Geoinformationssysteme*, (2):12–17.

# Danksagung

An dieser Stelle möchte mich bei den Menschen bedanken, die zum Gelingen der Arbeit beigetragen haben.

Zunächst danke ich Prof. Dr.-Ing. Wolfgang Förstner für die Betreuung dieser Arbeit. Seine stetige Bereitschaft durch kritische Fragen Sachverhalte zu klären und wissenschaftlich zu motivieren, hat die Arbeit zu dem werden lassen, was sie ist.

Mein Dank gilt auch Prof. Dr.-Ing., Dr.-Ing. E.h. mult. Karl-Rudolf Koch für die Übernahme des ersten Korreferats. Während meiner Zeit an seinem Institut, dem Institut für Theoretische Geodäsie, ist in mir die Liebe zu den netzbasierten statistischen Verfahren gewachsen. Aus dem, was ich in dieser Zeit gelernt habe, resultierte dann auch ein Teil der Ideen dieser Arbeit.

Prof. Neumann danke ich für die Erstellung des dritten Gutachtens.

Den Kollegen am Institut für Photogrammetrie danke ich die angenehme Arbeitsatmosphäre. Insbesondere danke Herrn Dipl.-Phys. Andre Braunmandl für die Bereitstellung der Bibliothek für die doppelt verketteten Kantenlisten.

Meiner Frau möchte ich für ihre stetige Unterstützung und Überzeugung, dass die Arbeit doch nochmal fertig wird, danken. Ohne ihre Unterstützung wäre diese Arbeit wahrscheinlich nie abgeschlossen worden.

Meinen Eltern danke ich dafür, dass sie nach dem Studium die Idee der Promotion akzeptiert haben, obwohl dadurch die Fortführung des eigenen ÖbVI Büros gefährdet war.

Darüber hinaus bedanke ich mich bei dem Bundesministerium für Bildung, Forschung, Wissenschaft und Technik (BMBF), der Europäischen Union (EU) und der Deutschen Forschungsgemeinschaft (DFG), die durch Projektförderungen diese Arbeiten erst ermöglicht haben.



# Lebenslauf

Name	<u>Ansgar</u> Elmar Maria Brunn
Wohnort	Lichweg 79 53757 Sankt Augustin (Meindorf)
Geburt	29.07.1968 in 33034 Brakel (Krs. Höxter)
Schulausbildung	1974-1978 Kath. Grundschule Brakel 1978-1987 Städt. Petrus-Legge-Gymnasium Brakel Abschluss: Abitur im Mai 1987
Wehrpflicht	Grundwehrdienst beim Wachbatallion in Bergisch Gladbach anschließend beim Heeresmusikkorps 100 in Münster
Praktika	Mai/Juni 1987 beim Landesvermessungsamt Nordrhein-Westfalen in Bonn-Bad Godesberg September 1988 beim Landschaftsverband Westfalen-Lippe in Münster
Studium	1988 - 1993 an der Rheinischen Friedrich-Wilhelms-Universität in Bonn
Berufliche Tätigkeiten	Abschluss: Diplom am 25. März 1993 April bis September 1993 beim Institut für Theoretische Geodäsie, Bonn,
Familienstand	seit 1993 am Institut für Photogrammetrie, Bonn verheiratet mit Anne-Kristin Brunn, geb. Dohmann, Tochter Victoria-Leandra Brunn