



**DGK** Veröffentlichungen der DGK  
Ausschuss Geodäsie der Bayerischen Akademie der Wissenschaften

---

Reihe C

Dissertationen

Heft Nr. 786

**Alena H. C. Schmidt**

**Markierte Punktprozesse  
für die automatische Extraktion von Liniennetzen  
in Rasterdaten**

**München 2017**

**Verlag der Bayerischen Akademie der Wissenschaften**

**ISSN 0065-5325**

**ISBN 978-3-7696-5198-0**

---

**Diese Arbeit ist gleichzeitig veröffentlicht in:  
Wissenschaftliche Arbeiten der Fachrichtung Geodäsie und Geoinformatik der Leibniz Universität Hannover  
ISSN 0174-1454, Nr. 330, Hannover 2016**





DGK Veröffentlichungen der DGK

Ausschuss Geodäsie der Bayerischen Akademie der Wissenschaften

---

Reihe C

Dissertationen

Heft Nr. 786

**Markierte Punktprozesse  
für die automatische Extraktion von Liniennetzen  
in Rasterdaten**

Von der Fakultät für Bauingenieurwesen und Geodäsie  
der Gottfried Wilhelm Leibniz Universität Hannover  
zur Erlangung des Grades  
Doktor-Ingenieur (Dr.-Ing.)  
genehmigte Dissertation

von

**M.Sc. Alena H. C. Schmidt**

**München 2017**

Verlag der Bayerischen Akademie der Wissenschaften  
in Kommission bei der C. H. Beck'schen Verlagsbuchhandlung München

ISSN 0065-5325

ISBN 978-3-7696-5198-0

---

Diese Arbeit ist gleichzeitig veröffentlicht in:  
Wissenschaftliche Arbeiten der Fachrichtung Geodäsie und Geoinformatik der Leibniz Universität Hannover  
ISSN 0174-1454, Nr. 330, Hannover 2016

Adresse der DGK:



Ausschuss Geodäsie der Bayerischen Akademie der Wissenschaften (DGK)

Alfons-Goppel-Straße 11 • D – 80 539 München

Telefon +49 – 89 – 23 031 1113 • Telefax +49 – 89 – 23 031 -1283 / - 1100

e-mail dgk-post@dgk.badw.de • <http://www.dgk.badw.de>

Prüfungskommission:

Vorsitzender: Prof. Dr.-Ing. Winrich Voss

Referent: Prof. Dr.-Ing. Christian Heipke

Korreferenten: Prof. Dr.-Ing. Uwe Sörgel

apl. Prof. Dr.-Ing. Claus Brenner

apl. Prof. Dr. techn. Franz Rottensteiner

Tag der mündlichen Prüfung: 12.12.2016

---

© 2017 Bayerische Akademie der Wissenschaften, München

Alle Rechte vorbehalten. Ohne Genehmigung der Herausgeber ist es auch nicht gestattet,  
die Veröffentlichung oder Teile daraus auf photomechanischem Wege (Photokopie, Mikrokopie) zu vervielfältigen

ISSN 0065-5325

ISBN 978-3-7696-5198-0

## Kurzfassung

Die Objektextraktion in Rasterdaten ist in der Fernerkundung und in vielen weiteren Disziplinen, in denen Bilddaten verwendet werden, von großer Wichtigkeit. Das Ziel ist es dabei, Pixel einer bestimmten Art von Objekt zu identifizieren und durch geeignete Modelle zu beschreiben. Auf Grundlage der extrahierten Objekte können dann z.B. Karten erstellt und aktualisiert werden.

In dieser Arbeit wird der automatischen Extraktion von Objekten nachgegangen, welche ein Liniennetz bilden. Unter dieser Zielsetzung ist ein neuer stochastischer Ansatz entwickelt worden, in welchem das Liniennetz als Graph repräsentiert ist. Da die Kernanwendung des entwickelten Verfahrens die Extraktion von Gewässernetzen ist, wird an den Graphen die Bedingung gestellt, dass er die Struktur von Bäumen – ungerichteten, azyklischen, planaren Graphen – aufweist. Dieses Modell wird in die probabilistische Methode der markierten Punktprozesse eingebunden. Verschiedene Konfigurationen des Graphen werden dann zufällig im Rahmen eines stochastischen Samplings erzeugt, indem die Parameter des Graphen modifiziert und Knoten und Kanten dem Graph hinzugefügt oder daraus entfernt werden. Für jede Konfiguration wird die Übereinstimmung bezüglich eines vorgegebenen Modells mit der Zielsetzung bestimmt, die Konfiguration mit der größten Übereinstimmung zu ermitteln. Diese wird anhand einer Energiefunktion bewertet, in welche Vorwissen über die Ausprägung des Liniennetzes in den Eingangsdaten sowie die zu erwartende Konfiguration einfließen. Für das stochastische Sampling wird die Reversible-Jump-Markov-Chain-Monte-Carlo-Methode gewählt. Hierdurch ist es möglich, Graphen mit einer unterschiedlichen Anzahl von Knoten und Kanten zu erzeugen und untereinander zu vergleichen. Durch die Kopplung des Verfahrens mit einem Simulated Annealing-Ansatz wird das globale Optimum der Energiefunktion iterativ angenähert. Als Ergebnis liegt derjenige Graph vor, der das Liniennetz in den gegebenen Daten am besten beschreibt.

Das Verfahren wird für Fluss- und Prielnetze in unterschiedlichen Geländeformen getestet. Als Eingangsdaten liegen dabei digitale Geländemodelle vor. Hierbei können Korrektheits- und Vollständigkeitsraten von  $> 60\%$  bei einer geometrischen Genauigkeit von bis zu 1 Pixel erzielt werden. Gegenüber Standardverfahren zur Gewässerextraktion lassen sich signifikante Genauigkeitssteigerungen erzielen. Darüber hinaus wird das Potential des vorgestellten Ansatzes für unterschiedliche Arten von Liniennetzen in Bilddaten evaluiert. Hier zeigen sich quantitativ ähnliche Ergebnisse im Vergleich zu anderen Verfahren in der Literatur.

**Schlagerworte:** Markierte Punktprozesse, Reversible-Jump-Markov-Chain-Monte-Carlo-Sampling, Graphen, digitale Geländemodelle



# Abstract

The object extraction in raster data is of great importance in remote sensing and further disciplines dealing with image data. In this regard, it is the goal to find pixels belonging to a specific type of object and to describe the objects by suitable models. On the basis of the extracted objects, for instance, maps can be generated or updated.

In this thesis, the automatic extraction of objects describing line-networks is investigated. With this goal, a new stochastic approach is proposed in which the line-network is represented as a graph. Because the main target application is the extraction of rivers and tidal channel networks, the graph is restricted to the structure of trees – undirected, acyclic, planar graphs. This model is embedded in the probabilistic framework of marked point processes. Different configurations of the graph are constructed randomly by modifying the graph parameters and by adding or removing nodes and edges to or from the current graph. Each configuration is evaluated with respect to a predefined model with the goal to find the configuration which fits the model best. For that purpose an energy function is formulated in which prior knowledge about the characteristics of the line-network in the input data and the expected configuration is integrated. For the stochastic sampling the Reversible Jump Markov Chain Monte Carlo method is chosen. In this way, graphs with different numbers of nodes and edges can be constructed and compared among each other. By coupling the approach with simulated annealing, the global optimum of the energy function is iteratively approximated. The result is the particular graph which best describes the line-network given the data.

The presented method is tested for river networks and tidal channel networks in different kinds of terrain. The used input data are digital terrain models. Here, the correctness and completeness rates are  $> 60\%$  with geometric accuracies up to 1 pixel. In comparison to standard methods for the extraction of water networks, significant increases of the accuracy can be achieved. Moreover, the potential of the presented approach for different types of line-networks in image data is evaluated. The results are quantitative comparable to other methods in the literature.

**Keywords:** Marked point processes, Reversible Jump Markov Chain Monte Carlo sampling, graphs, digital terrain models



# Inhaltsverzeichnis

<b>1. Einleitung</b>	<b>9</b>
1.1. Motivation . . . . .	9
1.2. Zielsetzung und wissenschaftlicher Beitrag . . . . .	11
1.3. Aufbau der Arbeit . . . . .	11
<b>2. Stand der Forschung</b>	<b>13</b>
2.1. Methoden für die Extraktion von Liniennetzen . . . . .	13
2.1.1. Flussnetze . . . . .	13
2.1.2. Straßen- und Gefäßnetze . . . . .	15
2.2. Methoden für die Objektextraktion mittels markierter Punktprozesse . . . . .	18
2.2.1. Einzelobjekte . . . . .	18
2.2.2. Liniennetze . . . . .	21
2.3. Diskussion . . . . .	23
<b>3. Grundlagen</b>	<b>25</b>
3.1. Punktprozesse . . . . .	25
3.1.1. Definition . . . . .	26
3.1.2. Poisson-Punktprozesse . . . . .	27
3.1.3. Gibbs-Punktprozesse . . . . .	27
3.1.4. Markierte Punktprozesse . . . . .	28
3.2. Monte-Carlo-Simulationsverfahren . . . . .	29
3.2.1. Sampling . . . . .	29
3.2.2. Markov-Chain-Monte-Carlo-Sampling . . . . .	30
3.2.3. Reversible-Jump-Markov-Chain-Monte-Carlo-Sampling . . . . .	32
3.2.4. Simulated Annealing . . . . .	33
3.3. Graphentheorie . . . . .	34
<b>4. Neue Methode für die Extraktion von Liniennetzen</b>	<b>37</b>
4.1. Objektmodell . . . . .	37
4.2. Energiefunktion . . . . .	39
4.2.1. Datenterm . . . . .	40
4.2.2. Priorterm . . . . .	42
4.3. Änderungen der Objektkonfiguration . . . . .	43
4.3.1. Birth-and-Death . . . . .	44
4.3.2. Modifikation . . . . .	45

4.3.3. Split-and-Merge . . . . .	46
4.4. Erweiterungen . . . . .	48
4.4.1. Wahrscheinlichkeitskarte . . . . .	48
4.4.2. Hierarchische Extraktion . . . . .	49
4.5. Konzeptioneller Ablauf . . . . .	50
4.6. Diskussion . . . . .	51
<b>5. Aufbau der Experimente</b>	<b>53</b>
5.1. Zielsetzung . . . . .	53
5.2. Daten . . . . .	54
5.3. Parametereinstellungen . . . . .	56
5.4. Evaluationsverfahren . . . . .	61
<b>6. Ergebnisse und Diskussion</b>	<b>65</b>
6.1. Analyse des Modells . . . . .	65
6.1.1. Einfluss des Abkühlungsverfahrens . . . . .	65
6.1.2. Einfluss der Energierme . . . . .	67
6.1.3. Einfluss der Ziehung von Zufallszahlen . . . . .	70
6.2. Extraktion von Gewässernetzen . . . . .	71
6.2.1. Anwendung für verschiedene Geländeformen . . . . .	71
6.2.2. Einfluss der Parameter . . . . .	77
6.2.3. Vergleich mit Standardverfahren . . . . .	82
6.2.4. Anwendung für Zeitreihen . . . . .	86
6.3. Extraktion von Liniennetzen in Bildern . . . . .	90
<b>7. Schlussfolgerungen und Ausblick</b>	<b>95</b>
<b>A. Anhang</b>	<b>99</b>
<b>Literaturverzeichnis</b>	<b>101</b>

# 1. Einleitung

## 1.1. Motivation

Die Abbildung und Beschreibung der Erdoberfläche und der darauf befindlichen Objekte ist wesentlicher Bestandteil der Geodäsie. Hierzu trägt die Fernerkundung bei, indem flugzeug- oder satellitengestützt Bilder mit Hilfe unterschiedlicher Sensoren aufgenommen und ausgewertet werden. Die Daten liegen nach einer Vorverarbeitung in der Regel in Form eines georeferenzierten Rasters vor. Jedes Pixel im Raster kann dabei eine unterschiedliche Information repräsentieren, beispielsweise ein Maß für die reflektierte Sonnenstrahlung an der dazugehörigen Position im optischen Bild oder deren Geländehöhe im digitalen Geländemodell (DGM). Für viele Anwendungen ist es bedeutsam, Objekte aus diesen Daten zu extrahieren. Die Extraktion von Straßen, Flüssen und Ortschaften ermöglicht z.B. die Einbindung dieser Information in eine topographische Karte. Erfolgt die Detektion bestimmter Geländestrukturen in Daten zu unterschiedlichen Zeitpunkten, können deren Dynamik bestimmt und Rückschlüsse auf geomorphologische Prozesse gezogen werden. Darüber hinaus weist die Objektextraktion aus Rasterdaten eine hohe Relevanz in zahlreichen weiteren Disziplinen auf, wie der Medizin [Lesage et al., 2009; Kirbas & Quek, 2004], der Robotik [Craig, 2005] oder der *Computer Vision* [Parker, 2011; Szeliski, 2010]. Die Zielsetzung ist in allen Fällen, die implizit in den Eingangsdaten enthaltene Information explizit werden zu lassen, um die Geometrie, Topologie oder Semantik bestimmter Objekte anzugeben. Wird dies ohne Eingriff des Nutzers durchgeführt, so spricht man von einer automatischen Extraktion.

In dieser Arbeit wird der automatischen Extraktion eines bestimmten Typs von Objekten nachgegangen: Objekten, die in der Regel als Liniennetz beschrieben werden. Unter einem Liniennetz wird im Folgenden eine Menge von Punkten verstanden, die über Linien miteinander verbunden sind. Die Linien verfügen dabei über eine Breite und liefern somit eine flächenhafte Repräsentation des Objektes. In unterschiedlichen Disziplinen treten Objekte auf, für die eine solche Beschreibung zutreffend ist, z.B. Flüsse und Straßen in Fernerkundungsdaten oder Nervenzellen und Blutadern in medizinischen Bildern. Die automatische Extraktion dieser Netze ist von großer Wichtigkeit, um Straßenkarten zu aktualisieren, Vorhersagen im Fall von Hochwasserereignissen zu machen, oder einen Beitrag für automatische Diagnoseprozesse in der Medizin zu liefern. Für eine besondere Form von Flussnetzen – Priele im Wattenmeer der Nordsee – ist die regelmäßige Erfassung darüber hinaus aufgrund der hohen Relevanz dieses Gebietes bezüglich der Ökologie und des Küstenschutzes Bestandteil verschiedener EU-Verordnungen [Europäische Kommission, 1992, 2000, 2008]. Im Folgenden liegt der Schwerpunkt auf der Extraktion von Gewässernetzen: Flussnetze an Land und Prielnetze im Wattenmeer. Als Eingangsdaten werden dabei digitale Geländemodelle (DGMs) verwendet. Darüber hinaus wird aber auch die Übertragbarkeit der neu entwickelten Methode auf verschiedene Liniennetze in Bildern untersucht.

Grundsätzlich finden sich für die automatische Extraktion von Objekten im Bereich der Bildanalyse eine Vielzahl an Methoden. Dabei ist es immer notwendig, Vorwissen (A-priori-Wissen), welches über die Objekte vorliegt, in das Modell einzubinden. Eine große Flexibilität bieten dabei probabilistische Verfahren, in denen das Wissen mit Hilfe von Wahrscheinlichkeitsverteilungen modelliert wird. Weit verbreitete probabilistische Methoden sind die erfolgreich in die Bildanalyse eingeführten *Markov Random Fields* [Geman & Geman, 1984] und *Conditional Random Fields* [Kumar & Hebert, 2003]. Die Rasterdaten sind hierbei als Graph repräsentiert, wobei die Knoten durch einzelne Pixel oder zuvor abgeleitete Segmente modelliert sind; über die Kanten ist lokaler Kontext eingebunden. Als A-priori-Wissen wird in der Regel angenommen, dass die Pixel in einer lokalen Nachbarschaft ähnliche Klassen aufweisen [Li, 1995]. Die Optimierung des Ergebnisses erfolgt dann über den pixel- oder segmentweisen lokalen Vergleich der Klassen bzw. Merkmale der Knoten. Während sich hierbei die Forderung nach ähnlichen Bildmerkmalen in einer lokalen Nachbarschaft leicht modellieren lässt, gestaltet es sich äußerst schwierig, globales Wissen über das Objekt – beispielsweise über dessen Form – einzubinden.

Dies ermöglichen modellbasierte probabilistische Verfahren, deren Stärke darin liegt, Objektwissen über den Vergleich von Bildmerkmalen einzelner Pixel oder Pixelgruppen hinausgehend zu modellieren. Eine vielversprechende Methode stellen in diesem Zusammenhang die *markierten Punktprozesse* dar, welche erfolgreich in verschiedenen Disziplinen eingesetzt wurden, wie der Astronomie [Babu & Feigelson, 1996], der Physik und der Biologie [Fleischer et al., 2006; Diggle, 2003; Ludwig & Reynolds, 1988]. Im Bereich der Fernerkundung sind Methoden basierend auf markierten Punktprozessen für die Objektextraktion in Rasterdaten [Benedek & Martorella, 2014; Chai et al., 2013; Lafarge et al., 2010; Tournaire et al., 2010; Ortner et al., 2007] und Punktwolken [Verdié & Lafarge, 2014; Descombes & Zerubia, 2002] entwickelt worden. Für terrestrische Bilder finden sich Beispiele bei Wenzel [2016] und Ge & Collins [2009].

Die Kernidee hinter dem Verfahren der markierten Punktprozesse ist es, Objekte mittels eines stochastischen Prozesses zu modellieren. Die Anzahl der Objekte, ihre Verteilung im Bild sowie ihre die Geometrie beschreibenden Parameter sind dabei als Zufallsvariablen modelliert. Zudem ist es möglich, Interaktionen zwischen den Objekten zu berücksichtigen. Durch die Verwendung von Simulationsverfahren lässt sich eine Vielzahl von Objektkonfigurationen erzeugen. Jede einzelne wird mit dem Ziel ausgewertet, die Konfiguration mit der besten Übereinstimmung bezüglich der Eingangsdaten und integriertem A-priori-Wissen aufzufinden. Markierte Punktprozesse sind charakterisiert durch (1) die Flexibilität beim Einbinden von Wissen über ein einzelnes Objekt und der Beziehung von mehreren Objekten untereinander, (2) die Variabilität bezüglich der Anzahl der Objekte, welche nicht von vornherein festgelegt werden muss, und (3) die Möglichkeit zum Auffinden einer im globalen Sinne optimalen Objektkonfiguration.

Für die Extraktion von Liniennetzen werden markierte Punktprozesse erfolgreich in der Literatur eingesetzt. Die Mehrzahl der Verfahren modelliert das Liniennetz dabei mit Hilfe einzelner Liniensegmente [Stoica et al., 2004, 2007; Lacoste et al., 2005; Sun et al., 2007; Kreher, 2007]. Als nachteilig erweist sich hierbei, dass Lücken zwischen den Liniensegmenten im Ergebnis auftreten. Dies kann umgangen werden, sobald das Liniennetz als Graph modelliert wird. Eine solche Idee ist in dem Ansatz von Chai et al. [2013] umgesetzt. Jedoch ist dieses Verfahren vornehmlich für die Extraktion von

Straßennetzen in optischen Fernerkundungsdaten konzipiert. Digitale Geländemodelle werden hierbei nicht als Eingangsdaten genutzt. Zudem enthält der resultierende Graph Zyklen. Dieses Modell ist für die Mehrzahl an Gewässernetzen nicht zutreffend, da sich Flüsse typischer Weise baumartig ausbreiten und sich das Netz von den großen Flüssen ausgehend immer stärker verästelt.

## 1.2. Zielsetzung und wissenschaftlicher Beitrag

Das Ziel dieser Arbeit ist es, Liniennetze aus digitalen Geländemodellen und optischen Bildern zu extrahieren, wobei als Kernanwendung die Extraktion von Gewässernetzen betrachtet wird. Der wissenschaftliche Beitrag lässt sich dabei wie folgt zusammenfassen:

- **Die Entwicklung eines neuartigen markierten Punktprozesses auf Basis der Graphentheorie.** Das Liniennetz wird als Graph modelliert. Die Verwendung einer Graphstruktur birgt den Vorteil, die Netzstruktur des Objektes direkt zu modellieren. Im Gegensatz zu Verfahren, die auf der Detektion einzelner Pixel oder isolierter Objekte beruhen, sind keine aufwendigen Nachbearbeitungsschritte erforderlich, um aus dem Ergebnis ein zusammenhängendes Liniennetz zu generieren. Im Kontext der markierten Punktprozesse werden Graphen als Objektmodell lediglich in den Arbeiten von Chai et al. [2013] in der Literatur genutzt. Jedoch sind hierbei in dem resultierenden Graphen Zyklen enthalten – ein Modell, das für die Beschreibung von Gewässernetzen in vielen Bereichen nicht geeignet erscheint. Aus diesem Grund wird in dieser Arbeit das Modell eines zyklensfreien Graphen, eines *Waldes*, erstmals als Objektmodell für markierte Punktprozesse eingeführt.
- **Die Integration von 3D-Information in das Modell.** Für die Extraktion von Gewässernetzen wird physikalisches Wissen eingebunden ("Wasser fließt in der Regel bergab"). In der Literatur liegen bislang keine Verfahren basierend auf markierten Punktprozessen vor, die physikalisches Wissen bezüglich der Höheninformation einfließen lassen.
- **Die Entwicklung eines auf Gewässernetze in unterschiedlichen Geländeformen und auf weitere Arten von Liniennetzen in Bilddaten übertragbaren Ansatzes.** An das gewählte Verfahren wird der Anspruch gestellt, vielfältig hinsichtlich der Einsatzmöglichkeiten zu sein. So ist er für die Extraktion von Gewässernetzen in unterschiedlichen Geländeformen konzipiert. Gleichzeitig soll das Verfahren auf andere Arten von Liniennetzen (über Gewässer hinausgehend) in Bildern übertragbar sein.

## 1.3. Aufbau der Arbeit

Die Arbeit gliedert sich wie folgt. In Kapitel 2 wird zunächst ein Überblick über alternative Verfahren zur Extraktion von Liniennetzen in der Literatur gegeben, weiter werden Methoden zur Objektdetektion basierend auf markierten Punktprozessen vorgestellt. Anschließend werden die mathematischen Grundlagen der markierten Punktprozesse sowie das zu deren Lösung eingesetzte Sampling-Verfahren erläutert. Zudem sind wichtige Grundlagen aus dem Bereich der Graphentheorie angeführt (Kapitel 3).

Kapitel 4 enthält den in dieser Arbeit neu entwickelten Ansatz zur Extraktion von Liniennetzen. Der Aufbau der durchgeführten Experimente, die verwendeten Daten sowie das gewählte Evaluationsverfahren zur Bewertung der Ergebnisse werden in Kapitel 5 beschrieben. Eine Darstellung und Bewertung der Ergebnisse erfolgt in Kapitel 6, bevor eine Zusammenfassung der wichtigsten Erkenntnisse und ein Ausblick auf geeignete Erweiterungen diese Arbeit abschließen (Kapitel 7).

## 2. Stand der Forschung

In diesem Kapitel wird ein Überblick über verschiedene Verfahren in der Literatur zur Objektextraktion gegeben. Auf zwei Gruppen von Methoden wird dabei eingegangen: Verfahren, die Liniennetze extrahieren (Abschnitt 2.1), sowie Verfahren, die zur Objektextraktion markierte Punktprozesse einsetzen (Abschnitt 2.2). Abschließend erfolgt eine Bewertung der aufgezeigten Ansätze und eine Einordnung der in dieser Arbeit entwickelten Methode (Abschnitt 2.3).

### 2.1. Methoden für die Extraktion von Liniennetzen

Netze kommen in der Natur und bei von Menschen geschaffenen Objekten vielfältig vor. Auf die drei Beispiele (1) Flussnetze, (2) Straßennetze und (3) Gefäßnetze in medizinischen Daten wird im Folgenden näher eingegangen (Beispiele siehe Abbildung 2.1). Für deren Extraktion in Rasterdaten sind in der Forschung unterschiedliche Ansätze entwickelt worden. Diejenigen, die sich mit der Erkennung von Flussnetzen beschäftigen (siehe Abschnitt 2.1.1), unterscheiden sich von den anderen beiden insofern, als dass hierfür nahezu ausschließlich DGMs als Eingangsdaten verwendet werden und zumeist physikalisches Wissen in der Form integriert ist, dass das Fließen von Wasser im Netz möglich sein muss. Verfahren zur Extraktion von Straßen- bzw. Gefäßnetzen (siehe Abschnitt 2.1.2) basieren hingegen zumeist auf Grauwertmerkmalen in Bildern und Wissen über die Struktur des Netzes.

#### 2.1.1. Flussnetze

Für hydrologische Anwendungen wurden verschiedene Ansätze entwickelt, die die Detektion von Flüssen und Entwässerungsnetzen zum Ziel haben. Dies ist bedeutsam, um u.a. im Falle von starken Niederschlägen oder Überflutungen Voraussagen über den Lauf des Wassers im Gelände zu machen.



**Abbildung 2.1.:** Beispiele für natürliche und künstliche Netze: (a) Flüsse, (b, c) Straßen [©Google] und (d, e) Gefäße [©WeltN24; Benmansour & Cohen, 2011]

Sogenannte *Flow Routing*-Algorithmen [Gruber & Peckham, 2009; Wilson et al., 2008] betrachten hierfür ausschließlich den Einfluss der Höhengradienten auf den Verlauf des Wassers. Unter der Annahme, dass das Wasser im Gelände stets den Weg des steilsten Gefälles nimmt, werden die Neigungen zwischen benachbarten Pixeln im DGM analysiert. Im Modell kann das Wasser dann ausschließlich in benachbarte Pixel mit geringerem Höhenwert fließen. Zwei Gruppen von Verfahren lassen sich hierbei unterscheiden: (1) *Single Flow*-Ansätze, bei denen das Wasser aus einem Pixel lediglich in eins der acht benachbarten Pixel fließen darf – z.B. *D8* [O’Callaghan & Mark, 1984], *R8* [Fairfield & Leymarie, 1991], *Kinematic Flow* [Lea, 1992] – und (2) *Multiple Flow*-Ansätze, bei denen sich das Wasser zwischen allen Nachbarn mit geringerem Höhenwert aufteilt – z.B. *TOPMODEL* [Quinn et al., 1991], *FD8* [Freeman, 1991], *MFD* [Holmgren, 1994]. Als Ergebnis der *Flow Routing*-Algorithmen liegt das Wassereinzugsgebiet (*catchment area*) vor, welches jedem Pixel im DGM die Summe aller Pixel zuweist, aus denen Wasser aufgrund der Geländeneigung in das aktuelle Pixel fließt. Ist die Summe ausreichend groß und übersteigt einen vorab definierten Schwellwert, wird das Pixel als zum Netz zugehörig ausgegeben. Insgesamt zeichnen sich die *Flow Routing*-Algorithmen durch eine effiziente Berechnung des Netzes aus, sie sind zudem in einigen GIS-Anwendungen implementiert. Jedoch sind diese Verfahren in erster Linie für die Extraktion von Flussnetzen in Gebieten mit starken Höhenunterschieden konzipiert und lassen sich nicht vollständig auf hydrologische Fragestellungen in Gebieten mit nahezu horizontalem Geländeverlauf – wie der Extraktion von Prielnetzen im Watt – übertragen [Lohani & Mason, 2001].

Priele unterscheiden sich auch sonst in ihrer Charakteristik von anderen Flussläufen [Hughes, 2012], was insbesondere auf den tidenbedingten Wechsel der Fließrichtung viermal täglich zurückgeführt werden kann. Spezielle Extraktionsverfahren sind für Prielnetze entwickelt worden, welche insbesondere auf Verfahren aus der Bildanalyse beruhen. So bestimmen beispielsweise Fagherazzi et al. [1999] Höhen und Geländekrümmungen in DGMs unterschiedlicher Auflösungen und kombinieren beide Merkmale in einem schwellwertbasierten Ansatz. Das Verfahren detektiert einen Großteil der Priele in den Eingangsdaten. Einige kleinere Priele fehlen jedoch im Ergebnis, zudem wird kein zusammenhängendes Netz erkannt. Im Gegensatz hierzu entwickeln Mason et al. [2006] ein Kriterium für die Verbundenheit von Prielen. Nach Anwendung einfacher Bildverarbeitungsoperatoren werden parallele Kanten unter Berücksichtigung von Richtungen und Distanzen gesucht. Zudem wird die Mittelachse der Priele abgeleitet und Lücken im Netz werden durch Auswertung der Richtungen der Priele geschlossen. Die Autoren kombinieren den Ansatz darüber hinaus mit optischen Eingangsdaten, was jedoch zu keiner Verbesserung der Ergebnisse führt [Lohani et al., 2006]. Die Klassifikation von Wattgebieten ist Zielsetzung in den Arbeiten von Brzank [2008] und Schmidt et al. [2013, 2014]. Anstelle eines regelmäßigen DGM werden hierbei Laserscannerpunktwolken als Eingangsdaten verwendet. Diese werden als Vorverarbeitung für die Erstellung eines DGM mittels überwachter Klassifikationsverfahren in wasserbedeckte und trockengefallene Wattflächen klassifiziert. Es zeigt sich, dass die Wasser-Land-Klassifikation mit hohen Vollständigkeits- und Korrektheitsraten durchgeführt werden kann. Eine Vielzahl der wasserbedeckten Priele lassen sich auf diese Weise erkennen. Jedoch kann es vorkommen, dass die Klasse *Wasser* neben Prielen wasserbedeckte Senken im Ergebnis enthält oder einzelne Punkte falsch klassifiziert werden. Zudem liegt als Ergebnis eine klassifizierte Punktwolke vor, für die keine Nachbearbeitung in Form der Ableitung einer Netzstruktur der Priele erfolgt.

### 2.1.2. Straßen- und Gefäßnetze

Eine weitaus größere Anzahl an Verfahren zur Netzextraktion in Rasterdaten findet sich in der Literatur im Bereich der Straßendetektion, siehe z.B. [Mayer et al., 2006], und der Extraktion von Gefäßen und Neuronen in der Medizin, siehe z.B. [Kirbas & Quek, 2004; Lesage et al., 2009]. In Abhängigkeit der Extraktionsmethode lassen sich die Verfahren in unterschiedliche Gruppen einteilen. Im Folgenden werden exemplarisch wichtige Ansätze im Bereich der Straßen- und Gefäßextraktion vorgestellt und in lokale und globale Methoden unterteilt. Als lokal werden Methoden bewertet, die das Netz ausschließlich auf Grundlage lokaler Bildmerkmale ableiten. Im Gegensatz dazu optimieren globale Methoden das Netz hinsichtlich der gesamten Eingangsszene.

**Lokale Methoden basierend auf Tracking:** Tracking-Verfahren breiten das Netz von einem oder mehreren vom Nutzer vorgegebenen Startpunkten und -richtungen unter Ausnutzung von lokalen Bildmerkmalen und Vorwissen aus und fügen Pixel nach und nach dem Netz hinzu.

Vosselman & de Knecht [1995] und Movaghati et al. [2010] nutzen hierfür einen *Kalman-Filter*. Pixel quer zur Ausbreitungsrichtung werden mit Straßenprofilen aus Referenzdaten verglichen. Liegt eine Übereinstimmung vor, werden die Pixel dem Netz hinzugefügt und die Parameter im Modell aktualisiert. Andernfalls wird die Suche entsprechend der letzten Parameter fortgeführt oder im Fall von unveränderten Parametern über mehrere Iterationen abgebrochen. Movaghati et al. [2010] integrieren zusätzlich einen Partikelfilter, der das Auffinden von Pixeln mit typischen Straßenmerkmalen in der lokalen Nachbarschaft ermöglicht. Auf diese Weise lassen sich Hindernisse und Kreuzungen erfolgreich überbrücken. Geman & Jedynek [1996] werten Pixel in der lokalen Nachbarschaft mit Hilfe von statistischen Tests aus. Hierbei fließen Annahmen über das Straßennetz bezüglich der Breite, Richtung und Krümmung ein. Die Pixel, die zu der größten Wahrscheinlichkeit führen, werden dem Netz hinzugefügt und bilden den Ausgangspunkt für die nächsten Abfragen. Im Ansatz von McKeown & Denlinger [1988] sind zwei lokale Methoden kombiniert. Diese beruhen auf der Auswertung von Texturen und der Bestimmung paralleler Kanten. Sofern das Tracking mit einem der Verfahren abgebrochen wird, wird automatisch die alternative Methode ausgewählt und hiermit die Suche nach dem Straßennetz fortgesetzt. Hu et al. [2007] breiten ein Straßennetz auf Grundlage von zuvor erstellten Segmentierungsergebnissen aus. Die Form der Segmente wird dabei analysiert und in den dominierenden Richtungen nach Nachbarsegmenten mit ähnlichen Grauwerten gesucht. Trackingansätze in der Medizin [Chothani et al., 2011; Bas & Erdogmus, 2011] nutzen Merkmale, die aus den Grauwerten und der Hesse-Matrix abgeleitet sind, um Nervenzellen in Mikroskopdaten zu extrahieren.

Als grundsätzliche Einschränkung der Tracking-Verfahren lässt sich das erforderliche Eingreifen des Nutzers anführen, welcher in der Mehrzahl der vorgestellten Verfahren Startwerte manuell vorzugeben hat [McKeown & Denlinger, 1988; Vosselman & de Knecht, 1995; Geman & Jedynek, 1996; Movaghati et al., 2010; Bas & Erdogmus, 2011]. Zudem können bei Tracking-Ansätzen fehlerhafte Entscheidungen auf Grundlage lokaler Eigenschaften getroffen werden. Zu einem späteren Zeitpunkt lassen sich diese nicht mehr korrigieren. Beispielsweise kann es vorkommen, dass das Netz im Fall von nah beieinander liegenden Straßen oder Nervenzellen topologisch inkorrekt fortgesetzt wird. Als nachteilig wirkt es sich zudem aus, wenn das Netz von anderen Objekten in den Daten verdeckt ist.

**Lokale Methoden basierend auf einer Klassifikation oder Segmentierung:** Eine Vielzahl von Methoden detektiert zunächst Teile des Netzes mit Hilfe eines lokalen Segmentierungs- oder Klassifikationsansatzes und gruppiert das Ergebnis anschließend auf Grundlage vorab definierter Regeln. Im Allgemeinen wird dabei A-priori-Wissen in heuristischer Form integriert.

Liegt das Ergebnis einer Segmentierung vor, erfolgt die Gruppierung im Bereich der Straßenextraktion über den Vergleich von Distanzen und Richtungen benachbarter Segmente mit vorab definierten Kriterien [Gamba et al., 2006; Poullis & You, 2010; Grote et al., 2012]. Baumgartner et al. [1999] und Grote et al. [2012] führen darüber hinaus kontextbezogene Merkmale ein, wie das Vorhandensein von Autos, Vegetation oder Schatten, was aus den Ergebnissen einer Klassifikation abgeleitet ist. Zhang [2004] integriert das Ergebnis einer unüberwachten Klassifikation in einen regelbasierten Ansatz. Jeder gefundenen Teilmenge wird vom Nutzer eine Bedeutung zugeordnet. Anschließend wird das Klassifikationsergebnis weiter untersucht und eine Änderung der Klasse einzelner Pixel vorgenommen, sofern bestimmte Kriterien – beispielsweise bezüglich der Lage von Pixeln der Klassen *Vegetation* und *Schatten* hinsichtlich der gefundenen Straßenpixel – erfüllt sind. Luftgestützte Laserscannerdaten werden in dem Verfahren von Clode et al. [2007] zunächst in Straßen- und Hintergrundpixel klassifiziert. Hierfür werden die Höhen bezüglich eines abgeleiteten DGM sowie die Intensitäten der Laserscannerdaten ausgewertet. In einem zweiten Schritt erfolgt dann eine Vektorisierung des Klassifikationsergebnisses. Eine binäre Klassifikation basierend auf neuronalen Netzen wird bei Mnih & Hinton [2010] und Marín et al. [2011] genutzt, um Straßen bzw. Gefäße zu detektieren. Das Ergebnis wird durch Anwendung lokaler Filter nachbearbeitet, Pixellücken gefüllt und isolierte Pixel gelöscht.

Als nachteilig erweist sich, dass die aufgezeigten lokalen Verfahren eine Vielzahl von Parametern mitführen, die für jede Szene anzupassen sind. Zudem hängt das Ergebnis von der vorab durchgeführten Segmentierung oder Klassifikation ab.

**Globale graphenbasierte Methoden:** Im Gegensatz zu lokalen Methoden, die das Netz auf Grundlage lokaler Bildmerkmale ableiten, optimieren globale Ansätze das Netz hinsichtlich der gesamten Eingangsszene. Einige Verfahren in der Literatur gehen dabei ähnlich wie die zuletzt angeführte Gruppe von Ansätzen vor und klassifizieren oder segmentieren zunächst die Eingangsszene auf Grundlage lokaler Bildmerkmale. Das Ergebnis wird anschließend in die Struktur eines Graphen überführt. Hierbei repräsentieren die Knoten einzelne Bildsegmente, die über eine hohe Wahrscheinlichkeit verfügen, zum Netz zu gehören. Kanten stellen die möglichen Verbindungen dazwischen dar. Mittels Optimierungsverfahren, wie die Suche nach kostengünstigen Pfaden, wird dann die global beste Lösung für das Liniennetz bestimmt.

So kombinieren Fischler et al. [1981] die Ergebnisse verschiedener Liniendetektoren und leiten daraus eine Wahrscheinlichkeit für jedes Pixel ab, zum Straßennetz zu gehören. Anschließend wird der A\*-Algorithmus mit dem Ziel angewandt, den Pfad mit den geringsten Kosten (d.h. den mit den höchsten Wahrscheinlichkeiten) zu ermitteln. Ein ähnliches Vorgehen wählen Gerke et al. [2004] und Wiedemann [2002] sowie Hinz & Baumgartner [2003], um das optimale Netzwerk auf Grundlage der vorab detektierten Straßensegmente zu bestimmen. Hierbei werden Abstand und Winkel zwischen einzelnen Straßensegmenten oder die Homogenität von Grauwerten bewertet. Im Bereich der Gefäßdetektion

berechnen Türetken et al. [2012, 2013] und Zhao et al. [2011] Wahrscheinlichkeiten für jedes Pixel, sich auf einer röhrenförmigen Struktur zu befinden, und nutzen diese als Kriterium für die Bestimmung des optimalen Pfads.

Als vorteilhaft kann herausgestellt werden, dass in den aufgeführten Verfahren eine global optimierte Lösung für die Eingangsdaten gefunden wird. Diese hängt jedoch stark von dem Ergebnis der Vorverarbeitung ab, aus welcher die Knoten und Kanten des Graphen abgeleitet werden. Werden hierbei fehlerhafte Zuordnungen getroffen und Hintergrundpixel als Knoten im Graphen eingeführt, kann eine solche Entscheidung zu einem späteren Zeitpunkt nicht rückgängig gemacht werden. Zudem ist die Anzahl an Knoten im Graphen fest und lässt sich während der Optimierung nicht ändern.

**Globale Methoden basierend auf aktiven Konturen:** Verfahren, die auf den aktiven parametrischen Konturen (*Snakes*) [Kass et al., 1988] basieren, initialisieren zunächst die Kontur des Liniennetzes mit einer vorgegebenen Kurve. Diese wird anschließend durch den Einfluss von internen Kräften, welche Glattheitsbedingungen über die Kontur einführen, und externen Kräften, die die Kontur hinsichtlich der Eingangsdaten anpassen, iterativ deformiert. Die optimale Kontur wird durch Minimierung einer Energiefunktion bestimmt, die interne und externe Kräfte vereinigt.

Für Straßennetze werden als interne und externe Kräfte Bedingungen bezüglich der Linearität und Straßenbreite sowie der Grauwertmerkmale in optischen Bildern [Gruen & Li, 1995] und SAR-Daten [Bentabet et al., 2003] formuliert. Law & Chung [2010] nutzen Merkmale über die Charakteristik von Blutbahnen aus, um diese mittels eines *Snake*-Ansatzes zu extrahieren. Wang et al. [2011] lassen die aktive Kontur zudem während der Optimierung wachsen, sofern benachbarte Pixel ähnliche Merkmale in den Daten aufweisen. Aktive Konturen höherer Ordnung lassen neben linearen Termen auch Terme höherer Ordnung in die Energiefunktion einfließen, was sich während der Energieminimierung als günstig erweist, um lokale Minima zu umgehen [Rochery et al., 2006]. Die Optimierung wird in diesem Ansatz mittels einer *Level set*-Methode [Osher & Sethian, 1988] anstelle eines *Snake*-Ansatzes durchgeführt. Für Verfahren basierend auf *Snakes* finden sich in der Literatur eine Vielzahl von Erweiterungen hinsichtlich der Parametrisierung der Kontur vor: z.B. *Ribbon Snakes*, bei denen die Breite der Straße mitgeführt werden kann und die Bildenergie an den Straßenrändern ausgewertet wird [Fua, 1997; Baumgartner et al., 1999] oder *Network Snakes*, die die Kontur als Graph modellieren und auf diese Weise die Topologie berücksichtigen können [Butenuth & Heipke, 2012]. Ein Ansatz, der beide Modelle kombiniert, ist in den Arbeiten von Göpfert et al. [2011] entwickelt.

Allgemein erfordert die Modellierung mittels aktiver Konturen eine Initialisierung des Netzes und macht diese Methoden daher besonders geeignet für Anwendungen, in denen eine genäherte Kontur vorliegt (z.B. in Form eines genäherten Straßennetzes) bzw. in denen diese in einer einfachen Vorverarbeitung gut ermittelt werden kann [Koutaki et al., 2006]. Liegt dieses Vorwissen hingegen nicht vor, erweisen sich die aufgezeigten Verfahren als nicht geeignet.

**Methoden basierend auf graphischen Modellen:** Eine weitere Möglichkeit liegt darin, die Aufgabe der Netzextraktion in eine Bildklassifikation basierend auf graphischen Modellen wie *Markov Random Fields* (MRF) und *Conditional Random Fields* (CRF) zu integrieren.

Für die Straßenextraktion in SAR-Daten bestimmen Tupin et al. [1998] und Katartzis et al. [2001] zunächst Liniensegmente durch Kombination der Ergebnisse verschiedener Bildverarbeitungsoperatoren und führen zusätzlich Verbindungen ein, indem die Distanz und die Winkel zwischen den Liniensegmenten ausgewertet werden. Die Liniensegmente werden anschließend in ein MRF überführt und als *Straße* oder *Hintergrund* klassifiziert. Ausschlaggebend sind hierfür die Wahrscheinlichkeiten für die Zugehörigkeit jedes einzelnen Pixels entlang eines Segments zu einer der beiden angeführten Klassen. Zudem werden globale Kriterien betrachtet, die die Länge einer Straße, deren Krümmung sowie die Anzahl von Kreuzungen in der Szene berücksichtigen. Montoya-Zegarra et al. [2014] und Wegner et al. [2015] berechnen Wahrscheinlichkeiten für jedes Pixel bzw. Superpixel in der Szene, zu der Klasse *Straße* zu gehören. Dabei werden zufällig Paare von Primitiven mit hohen Wahrscheinlichkeiten ausgewählt und mittels eines optimalen Pfads verbunden. Globaler Kontext ist über die Verwendung von Cliques höherer Ordnung in einem CRF integriert. Mit der Zielsetzung, Cliques zu erhalten, in denen möglichst alle Pixel einer Klasse zugeordnet sind, erfolgt die Optimierung des Klassifikationsergebnisses.

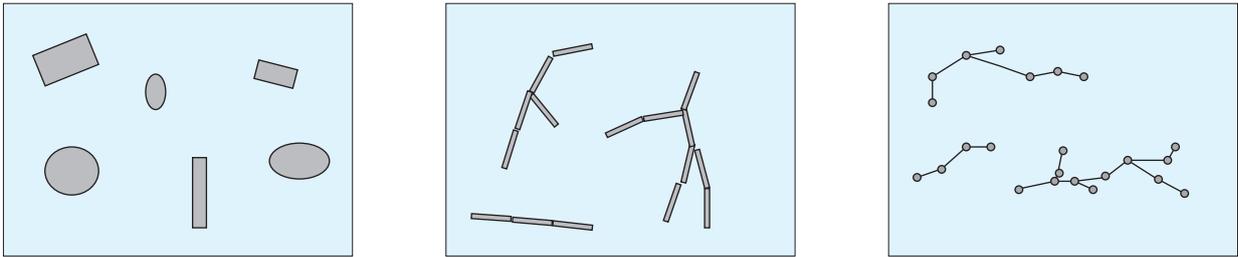
Auch wenn auf diese Weise globales Wissen integriert wird, ist es schwierig, globale Bedingungen – wie die über die Form der Objekte – einzubinden. So ist auch die Struktur eines Liniennetzes nicht gut abbildbar in einem Modell, welches auf MRF oder CRF beruht.

## 2.2. Methoden für die Objektextraktion mittels markierter Punktprozesse

Eine Alternative zu den angeführten Verfahren stellt der modellbasierte, probabilistische Ansatz der markierten Punktprozesse dar. Dieser wird seit über 20 Jahren erfolgreich für die Objektextraktion in der Bildanalyse eingesetzt [Baddeley & van Lieshout, 1993; Rue et al., 1999]. Im Rahmen eines Simulationsansatzes werden hierbei verschiedene Objektkonfigurationen erzeugt. Die Konfiguration, die die Daten unter Berücksichtigung von Vorwissen am besten beschreibt, wird mittels einer Optimierung in Form einer Energieminimierung bestimmt. Die Energiefunktion setzt sich dabei zumeist aus einem Daten- und einem Priorterm zusammen. Hierüber lassen sich die Übereinstimmungen mit den Eingangsdaten bzw. mit A-priori-Wissen über die Konfiguration bewerten. Als Ergebnis liegt jene Objektkonfiguration vor, für die die Energie minimal ist. Die Anwendungen der markierten Punktprozesse reichen in der Objektextraktion von der Detektion einzelner, isolierter Objekte (Abschnitt 2.2.1) bis hin zu der Extraktion von Liniennetzen (Abschnitt 2.2.2). Beispiele für beide Arten von Anwendungen sind in Abbildung 2.2 dargestellt.

### 2.2.1. Einzelobjekte

**Einzelne Objekttypen:** In der Regel werden einfache geometrische Primitive gewählt, um das Objekt in den Daten zu beschreiben. So nutzen Ortner et al. [2007] und Tournaire et al. [2010] das Modell eines Rechtecks, um Gebäude in digitalen Oberflächenmodellen (DOM) zu beschreiben. Senkrecht zu den Rechteckskanten bzw. entlang dieser werden die Höhen im DOM analysiert. Der Datenterm



**Abbildung 2.2.:** Im markierten Punktprozess können unterschiedliche Modelle zur Beschreibung des Objektes genutzt werden. Handelt es sich um einzelne, isolierte Objekte, werden in der Regel einfache geometrische Primitive wie Rechtecke, Kreise oder Ellipsen gewählt (links). Für Liniennetze finden Liniensegmente (Mitte) und Graphen (rechts) als Objektmodell Verwendung.

überprüft, ob die Gradientenmagnituden an den Rechteckskanten hoch sind. Eine Reduktion der Energie bewirken darüber hinaus nicht-überlappende und parallele Objekte. Bei optischen Eingangsdaten fließen für dieselbe Aufgabenstellung Annahmen über die Grauwertverteilungen in den Datenterm ein [Benedek et al., 2012; Chai et al., 2012]. Ersterer Ansatz formuliert zudem Bedingungen über den Schattenwurf bei gegebenem Sonnenstand zum Aufnahmezeitpunkt. Auch lassen sich über Rechtecke Straßenmarkierungen modellieren [Tournaire & Paparoditis, 2009]. Ausschlaggebend sind hierbei die Differenz der Grauwerte zwischen Objekt und Hintergrund sowie Kriterien bezüglich der Distanz und Orientierung der Markierungen untereinander. Li & Li [2010] geben mit Hilfe eines Rechtecks den Begrenzungsrahmen von zu detektierenden Ölteppichen in SAR-Daten an. In den Datenterm fließt hierbei Vorwissen über die Rückstreuung des SAR-Signals bei Ölteppichen ein. Ellipsen bzw. Kreise finden als Modell Verwendung, um die Umrisse von Baumkronen bzw. Flamingos in optischen Luft- und Satellitenbildern [Perrin et al., 2005; Descamps et al., 2008; Descombes et al., 2009] oder segmentierten luftgestützten Laserscannerdaten [Zhang et al., 2013] zu approximieren. In allen Ansätzen wird die Überlappung von Objekten bestraft. Perrin et al. [2005], Descamps et al. [2008] und Descombes et al. [2009] werten zudem die Grauwerte innerhalb und außerhalb der Objekte aus, deren Verteilung sich signifikant unterscheiden muss, um ein neu vorgeschlagenes Objekt anzunehmen. Im Ansatz von Perrin et al. [2005; 2006] sind regelmäßige Abstände zwischen Bäumen im Priorterm gefordert, zudem werden neue Objekte bevorzugt in einer vordefinierten Distanz zu bereits angenommenen Objekten vorgeschlagen. Die Methode von Zhang et al. [2013] bewertet darüber hinaus die Symmetrien der Segmentierungsergebnisse bezüglich der vorgeschlagenen kreisförmigen Objekte.

Die Modellierung von einfachen geometrischen Primitiven hat den Vorteil, dass für die Objektdefinition nur wenige Parameter benötigt werden und so der Suchraum während der Optimierung gering gehalten werden kann. Jedoch liegt hierbei die Annahme zugrunde, dass alle Objekte in der Szene eine ähnliche Charakteristik aufweisen, z.B. dass alle Gebäude über einen rechteckigen Grundriss verfügen. Variiert die Ausprägung der Objekte stark, stößt ein solches Modell an seine Grenzen.

**Mehrere Objekttypen:** Eine größere Flexibilität lässt sich erzielen, sofern mehrere geometrische Primitive kombiniert werden. So verwenden Ortner et al. [2008] zusätzlich zu Rechtecken Liniensegmente für die Gebäudeextraktion in einem DOM. Über Rechtecke erfolgt dabei die Suche nach homogenen Flächen, Liniensegmente werden genutzt, um Diskontinuitäten in Höhenprofilen zu analysieren.

Für jeden Geometriotyp liegt ein eigener Daten- und Priorterm vor. Zusätzlich ist durch Annahmen über Winkeldifferenzen und Distanzen zwischen Linienmittelpunkt und nächstgelegenen Rechteckspunkt die Interaktion zwischen beiden Geometriotypen modelliert. Benedek & Martorella [2014] kombinieren Linien und Punktgruppen, um in SAR-Bildsequenzen sich bewegende Schiffe und Flugzeuge zu extrahieren. Die Idee hierbei ist, dass diese sich in einem vorab ermittelten Klassifikationsergebnis linienhaft abzeichnen und mehrere Einzelpunkte ein lokales Intensitätsmaximum in den Eingangsdaten bilden. Im Optimierungsverfahren wird die Übereinstimmung dieser Annahmen mit den vorgeschlagenen Linien und Punktgruppen überprüft. Der Übergang auf mehr als zwei Geometriotypen gelingt Lafarge et al. [2010]. Hierbei wird eine Bibliothek von geometrischen Primitiven definiert (Kreise, Linien, Rechtecke). Die Besonderheit dieses Ansatzes liegt darin, dass neben den gängigen Änderungen in der Konfiguration wie dem Einfügen, Entfernen oder Modifizieren eines Objektes die Änderung des Geometriotyps zugelassen wird. Dies macht erforderlich, dass die sich ändernde Anzahl an Parametern beim Wechsel eines Geometriotyps in der Simulation modelliert ist.

Als günstig erweist es sich in den aufgezeigten Ansätzen, dass durch die Kombination mehrerer geometrischer Primitive für das Objekt unterschiedliche Formen von Vorwissen über dessen Ausprägung in den Daten modelliert werden können. Auf diese Weise nimmt jedoch auch die Komplexität des Modells zu, da das Zusammenwirken der einzelnen Primitive in das Modell aufgenommen werden muss. Zudem erhöht sich die Anzahl der Parameter und somit die Dimension des Suchraums, so dass von einer größeren Anzahl an Iterationen in der Optimierung auszugehen ist.

**Komplexe Objekte:** Nicht immer lassen sich die Objekte in den Daten durch einfache geometrische Primitive wie Punkte, Linien und Kreise approximieren. Hier besteht die Möglichkeit, ein komplexes Modell zu erstellen und gegebenenfalls mit einem einfachen Modell zu kombinieren. Hervieu et al. [2015] definieren Vorlagen für verschiedene Straßenmarkierungen (z.B. Pfeile oder das Symbol eines Fahrrads) und detektieren diese in Intensitätsbildern, die aus Laserscannerdaten von Mobile Mapping Systemen abgeleitet sind. Die Korrelation zwischen der Verteilung der Intensitätswerte des Modells mit denen in den Daten wird für die Bewertung eines Vorschlags herangezogen. Ge & Collins [2009] kombinieren komplexe Prototypen von Personenumrissen mit einem begrenzenden Rechteck, um Personen in Bilddaten zu detektieren. Im Optimierungsverfahren können sich sowohl die Parameter des Rechtecks ändern als auch ein neuer Prototyp für die darin enthaltene Person ausgewählt werden. Auf diese Weise ist es möglich, den groben Umriss einer Person zu einem frühen Zeitpunkt des Optimierungsverfahrens zu bestimmen und die genaue Kontur durch Änderungen des Prototyps später anzupassen.

Die Aufstellung eines komplexeren Modells ist in einigen der aufgezeigten Ansätze mit umfangreichen Vorverarbeitungsschritten verbunden, um geeignete Beschreibungen der Objekte zu finden. Beispielsweise wird in dem Ansatz von Ge & Collins [2009] zunächst ein Training durchgeführt, um Prototypen von Personenumrissen zu bestimmen. Als vorteilhaft kann herausgestellt werden, dass auf diese Weise eine detailliertere Beschreibung der Objekte möglich ist als bei der Approximation der Objekte mittels einfacher geometrischer Primitive. Jedoch sind die Objekte stark an die Art der Szene angepasst [Hervieu et al., 2015] und lassen sich nicht auf andere Anwendungen übertragen.

**Objekte in Punktwolken und 3D-Objekte:** In einigen Ansätzen in der Literatur liegen dreidimensionale Punktwolken als Eingangsdaten vor oder werden dreidimensionale Primitive als Objektmodell verwendet. So klassifizieren Börcs & Benedek [2015] zunächst eine Laserscannerpunktwolke für die Extraktion von Fahrzeugen und projizieren das Ergebnis in ein 2D-Bild. In das Klassifikationsergebnis werden dann Rechtecke derart hineingeschätzt, dass die Mehrzahl der Pixel innerhalb des Rechtecks der Klasse *Fahrzeug* angehört, während die Pixel im Hintergrund überwiegend andere Klassen aufweisen. Im Datenterm werden darüber hinaus die Intensitäten der projizierten Laserscannerdaten berücksichtigt. Der Priorterm bevorzugt ähnliche Objektgrößen innerhalb einer Nachbarschaft und für Gruppen von Fahrzeugen bestimmte Orientierungen und Abstände zur Klasse *Straße*. Utasi & Benedek [2011] schätzen direkt dreidimensionale Primitive in Form von Zylindern in die Daten multipler Kamerasysteme, um Personen darin zu detektieren. Der markierte Punktprozess wird dabei auf bereits in Vorder- und Hintergrund klassifizierte Daten angewandt. Konfigurationen mit überlappenden Zylindern und eine geringe Übereinstimmung mit den klassifizierten Vordergrundpixeln werden bestraft. Komplexere 3D-Modelle wurden bei Descombes & Zerubia [2002] und Verdié & Lafarge [2014] entwickelt. Erstere setzen ein Gebäudemodell – definiert über die Länge, Breite, Höhe und dem Zwischenwinkel der Dachhälften – ein, um Gebäude in Stereobildpaaren oder DOMs zu detektieren. In der Energiefunktion werden Überlappungen bestraft sowie homogene Grau- bzw. Höhenwerte innerhalb einer Dachhälfte im Stereobild bzw. DOM gefordert. Zudem sollen hohe Kontraste an den Gebäudekanten vorliegen. Verdié & Lafarge [2014] beschreiben über Kegel, Ellipsoide und Semiellipsoide Bäume in flugzeuggestützten Laserscannerdaten. Ähnliche Geometrietypen in der lokalen Nachbarschaft werden bevorzugt und Überlappungen bestraft. Der Datenterm bewertet die Distanz der Punkte zur Segmentbegrenzung der Bäume.

Die Verfahren zeigen, wie auch für unregelmäßige Punktwolken markierte Punktprozesse in der Objektextraktion erfolgreich eingesetzt werden können. Je nach Wahl des Modells kann hierbei die Komplexität zunehmen. Insgesamt haben die angeführten Beispiele den Nachteil, dass sie für die Extraktion isolierter Objekte konzipiert sind und sich daher nicht unmittelbar auf die Liniennetzextraktion übertragen lassen, sofern die Konnektivität erhalten bleiben soll.

### 2.2.2. Liniennetze

In den zuvor angeführten Beispielen werden Objekte detektiert, die in der Regel freistehend sind und durch isolierte Primitive modelliert werden können. Ein wesentliches Kriterium kommt im Folgenden hinzu, wenn es um die Extraktion von Liniennetzen geht. Hier ist es entscheidend, dass eine Verbindung zwischen den Objekten vorliegt.

**Netze aus Liniensegmenten und Zylindern:** Stoica et al. [2004] beschreiben das Netz durch einzelne Liniensegmente (Linien mit einer gewissen Breite). Die Liniensegmente werden nach und nach der Konfiguration hinzugefügt, wieder entfernt oder in ihrer Länge oder Orientierung modifiziert. Liniensegmente gelten dann als verbunden, wenn ihre Endpunkte innerhalb eines vorgegebenen Radius liegen. Während über den Datenterm überprüft wird, ob die Pixel innerhalb eines Liniensegments homogene Grauwerte aufweisen und sich von denen der Umgebung unterscheiden, greift der Priorterm

die wesentlichen Netzcharakteristiken auf. So wird ein Liniensegment bestraft, wenn es nur an einem Ende mit anderen Segmenten verbunden ist. Es wird noch stärker bestraft, wenn es an keinem Ende eine Verbindung aufweist. Darüber hinaus wird gefordert, dass Liniensegmente nicht überlappen, eine Mindestlänge aufweisen und sich nicht in einem sehr spitzen Winkel schneiden. Lacoste et al. [2005] bauen auf diesem Ansatz auf, verwenden jedoch keine konstanten Gewichte für die Priorterme, sondern modellieren diese in Abhängigkeit der Winkeldifferenz und Distanz benachbarter Liniensegmente. In den Datenterm fließen zudem statistische Tests ein. Sun et al. [2007] nutzen das Verfahren, um in medizinischen Bildern Gefäße zu extrahieren und bewerten im Datenterm die Übereinstimmung mit einer röhrenförmigen Struktur basierend auf den Eigenwerten der Hessematrix der Koordinaten.

Dreidimensionale Eingangsdaten werden von Stoica et al. [2007] verwendet. Hier werden Zylinder in dreidimensionale Abbildungen von Galaxien mit Hilfe markierter Punktprozesse geschätzt, um Materieansammlungen automatisch zu extrahieren. Die Wahl des Interaktionsterms ähnelt dem in 2D-Daten [Stoica et al., 2004]. So wird eine Verbundenheit der Zylinder gefordert, ferner sind Schwellwerte für die maximal mögliche bzw. zulässige Distanz zwischen zwei verbundenen bzw. unverbundenen Zylindern vorgegeben. Kreher [2007] wendet das Modell des Zylinders für die Detektion von Hirnnervenfasern in medizinischen Daten an. Eine Besonderheit dieses Ansatzes ist es, dass die Gehirnnervenfasern nicht nur untereinander, sondern auch mit der Gehirns substanz verbunden sein können. Dies wird im Modell aufgegriffen, in dem eine Verbundenheit mit weiteren Zylindern oder aber mit festen Bezugspunkten möglich ist.

Als vorteilhaft kann herausgestellt werden, dass durch die Liniensegmente bzw. Zylinder ein einfaches Objektmodell vorliegt, welches über eine geringe Anzahl von Parametern verfügt. Schwierig gestaltet es sich jedoch, die Verbundenheit von einzelnen Objekten zu definieren. In der Regel werden hierfür Schwellwerte für die Distanz der Endpunkte vorgegeben. Dennoch können Lücken im Ergebnis auftreten, so dass das Liniennetz nicht vollständig wiedergegeben ist.

**Netze als Graph:** Im Gegensatz zu den Verfahren basierend auf dem Modell von Liniensegmenten ist die Nachbarschaft zwischen einzelnen Objekten direkt vorgegeben, sobald als Objektmodell ein Graph gewählt wird. Chai et al. [2013] beschreiben ein Liniennetz über Kreuzungspunkte, bei denen es sich um Punkte mit mehreren abgehenden Liniensegmenten handelt. Der Aufbau des Graphen wird dabei iterativ vorgenommen. Ein neuer Kreuzungspunkt wird immer dann mit einer hohen Wahrscheinlichkeit hinzugefügt, wenn die Grauwerte innerhalb der abgehenden Segmente homogene Werte aufweisen sowie an deren Kanten hohe Gradientenbeträge auftreten. Über den Priorterm werden Konfigurationen bestraft, in denen nicht alle Knoten verbunden sind und in denen die Winkel zwischen den Kanten sowie die Anzahl der abgehenden Segmente von den aus Trainingsdaten gelernten Werten abweichen.

Insgesamt erweist sich ein Graph als Objektmodell als günstig, um Lücken an den Kreuzungen des Liniennetzes auszuschließen. Ein weiterer Vorteil besteht darin, dass ein direkter Zugriff zur Topologie gegeben ist und so das Liniennetz umfangreicher beschrieben werden kann. Jedoch liegen bislang keine Ansätze vor, die zyklensfreie Graphen als Objektmodell wählen. Zudem ist physikalisches Wissen unter Verwendung von digitalen Geländemodellen bislang nicht in solche Modelle eingebunden.

## 2.3. Diskussion

In der Literatur finden sich eine Vielzahl von Verfahren, die sich mit der Extraktion von Liniennetzen in Rasterdaten beschäftigen. Zu unterscheiden sind dabei Ansätze, die die Rasterdaten ausschließlich lokal auswerten und solche, die zusätzlich globale, die gesamte Szene betreffende Merkmale berücksichtigen. Da die lokalen Methoden in der Regel nur die Bildmerkmale in einer lokalen Nachbarschaft betrachten, lassen sie sich effizient berechnen. Nachteilig wirkt es sich hingegen aus, wenn das Liniennetz durch andere Objekte verdeckt oder Rauschen in den Daten enthalten ist. Dagegen sind lokale Verfahren nicht robust, das Liniennetz wird in diesen Bereichen nicht erkannt. Im Fall von Tracking-Ansätzen [Vosselman & de Knecht, 1995; Hu et al., 2007; Movaghati et al., 2010; Chothani et al., 2011; Bas & Erdogmus, 2011] kann es darüber hinaus vorkommen, dass die Suche aus einem solchen Grund abbricht und komplette Zweige des Liniennetzes nicht erkannt werden. Zudem ist es möglich, dass nah beieinanderliegende Zweige topologisch inkorrekt fortgesetzt werden.

Als günstig erweist es sich daher, wenn zusätzlich globale Eigenschaften verwendet werden. Eine Vielzahl von Methoden berücksichtigt die Eigenschaft von Liniennetzen, verbunden zu sein. Die Suche nach Verbindungen zwischen einzelnen Teilen des Liniennetzes ist dabei häufig einer Segmentierung [Baumgartner et al., 1999; Gamba et al., 2006; Poullis & You, 2010; Grote et al., 2012] oder Klassifikation [Clode et al., 2007; Zhang, 2004; Mnih & Hinton, 2010; Marín et al., 2011] der Eingangsdaten nachgeschaltet. Dies macht zum einen erforderlich, dass durch die Segmentierung bereits die wesentlichen Teile des Liniennetzes erkannt worden sind. Zum anderen sind in der Regel eine Vielzahl von Annahmen über die Zulässigkeit von Verbindungen zu definieren und zahlreiche Parameter zu setzen. Zwischen beiden Schritten besteht zudem eine Abhängigkeit, d.h. die optimale Parametrisierung der zweiten Methode (Suche nach Verbindungen zu einem Netz) hängt von der Parametrisierung der ersten Methode (Segmentierung oder Klassifikation) ab, was die Übertragbarkeit des Verfahrens einschränkt.

Graphenbasierte Verfahren haben den Vorteil, dass sie die Verbundenheit des Liniennetzes zusammen mit den lokalen Bildmerkmalen modellieren [Fischler et al., 1981; Wiedemann, 2002; Hinz & Baumgartner, 2003; Gerke et al., 2004; Türetken et al., 2012, 2013; Zhao et al., 2011]. Durch die Suche nach den optimalen Pfaden wird jenes Liniennetz gefunden, welches die gesamte Szene am besten beschreibt. Da die lokalen Merkmale aller Pixel entlang einer Kante ausgewertet werden, lässt sich Rauschen in den Daten besser überbrücken. Darüber hinaus profitieren graphenbasierte Verfahren davon, neben der Geometrie auch die Topologie des Liniennetzes zu liefern. Jedoch ist es hierfür erforderlich, den Graphen zunächst aufzustellen. Werden hierbei Fehler vorgenommen – z.B. in der Art, dass Bildsegmente als Knoten bestimmt werden, die gar nicht zum Netz dazugehören – wirkt sich dies direkt auf das Ergebnis aus, da eine Korrektur der Knoten in der Regel nicht vorgesehen ist.

Hier weisen die Verfahren der markierten Punktprozesse eine größere Flexibilität auf. Durch die Kopplung mit einem Sampling-Verfahren können jederzeit Objekte hinzugefügt aber auch wieder entfernt werden. Als Vorteil kann herausgestellt werden, dass als Ergebnis eine Objektkonfiguration vorliegt, die für die gesamte Eingangsszene optimiert ist. Die meisten Verfahren in der Literatur, die ein Liniennetz auf Grundlage von markierten Punktprozessen extrahieren, beschreiben das Netz über einzelne Liniensegmente [Stoica et al., 2004, 2007; Lacoste et al., 2005; Sun et al., 2007; Kreher, 2007].

Zusätzlich werden geometrische Bedingungen definiert, ab wann Liniensegmente als verbunden gelten. Die Verfahren haben die Einschränkung, dass ein direkter Zugriff auf die Topologie nicht gegeben ist.

Erfolgversprechend scheint es daher zu sein, eine Graphstruktur in einen markierten Punktprozess zu integrieren. Dies findet sich in der Literatur lediglich in den Arbeiten von Chai et al. [2013]. Jedoch beschränkt sich die Anwendung auf 2D-Bilddaten, ein Bezug zur Höhe in Fernerkundungsdaten ist nicht gegeben. Zudem werden in dem angeführten Ansatz u.a. Straßennetze extrahiert und daher Zyklen in den resultierenden Graphen zugelassen. Dieses Modell ist für den Großteil von Gewässernetzen nicht zutreffend. An beiden Punkten setzt diese Arbeit an. Im Folgenden wird ein neuer Ansatz zur Extraktion von Liniennetzen in Rasterdaten vorgestellt, der einen markierten Punktprozess auf Grundlage eines Graphen nutzt. Anstelle von optischen Bildern werden DGMs als Eingangsdaten verwendet. Mit der Zielsetzung, Gewässernetze darin zu extrahieren, wird ein Modell entwickelt. In der zu optimierenden Zielfunktion wird dabei physikalisches Wissen über das (Fluss-) Netz integriert und auf diese Weise die 3D-Information der Eingangsdaten ausgenutzt. Zudem wird für die Modellierung des Netzes eine Menge von Bäumen, welche als Wald bezeichnet wird, als Graphstruktur gewählt. Die Azyklizität im Netz kann auf diese Weise garantiert werden.

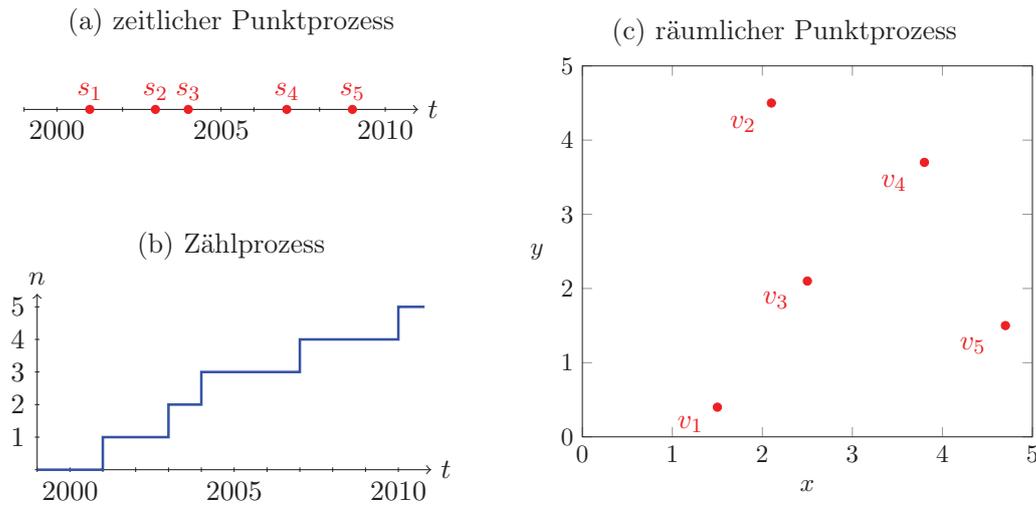
## 3. Grundlagen

In dieser Arbeit werden markierte Punktprozesse genutzt, um verschiedene Objektkonfigurationen in Rasterdaten zu generieren und hieraus die optimale Konfiguration zu bestimmen. Dieses Kapitel beschreibt zunächst die allgemeinen mathematischen Grundlagen der Punktprozesse und geht auf die speziellen Formen der *Poisson*- und der *Gibbs*-Punktprozesse sowie auf die markierten Punktprozesse ein (Abschnitt 3.1). Das Optimierungsproblem wird über Monte-Carlo-Methoden gelöst (Abschnitt 3.2). Nach der Einführung der *Markov-Chain-Monte-Carlo*-Ansätze wird auf zwei Erweiterungsmöglichkeiten eingegangen: die *Reversible-Jump-Markov-Chain-Monte-Carlo*-Methode, welche die Variation der Anzahl der zu schätzenden Parameter ermöglicht, sowie die Einbindung des *Simulated Annealing*, um das Verfahren gegen das Optimum der Zielverteilung konvergieren zu lassen. Da als Modell für das Objekt im markierten Punktprozess ein Graph gewählt wird, werden zudem einige Grundlagen der Graphentheorie beschrieben (Abschnitt 3.3).

### 3.1. Punktprozesse

Punktprozesse gehören zu der Gruppe der stochastischen Prozesse und basieren auf Grundlagen der Wahrscheinlichkeitstheorie. Grundsätzlich sind stochastische Prozesse geeignet, ein Zufallsgeschehen in der Natur mathematisch zu beschreiben. Im Gegensatz zu einem deterministischen Ansatz erfolgt hierbei die Modellierung in Form von Wahrscheinlichkeiten. Für eine ausführliche Beschreibung der Punktprozesse sei auf Chiu et al. [2013], Møller & Waagepetersen [2004], Daley & Vere-Jones [2003] und Van Lieshout [2000] verwiesen.

Die Realisierung eines Punktprozesses  $X$  setzt sich aus mehreren isolierten Punkten in einem mathematischen Raum – häufig mit zeitlichem oder räumlichem Bezug – zusammen. Der **zeitliche Punktprozess**  $X = \{s_1, s_2, \dots, s_n\}$  gibt die Zeitpunkte  $s_i$  ( $i = 1, \dots, n$ ) an, zu denen ein beobachtetes Ereignis auftritt (Abbildung 3.1a). Wird die Anzahl  $n$  an Ereignissen über ein zeitliches Intervall aufgetragen, spricht man von einem **Zählprozess** (Abbildung 3.1b). Anwendungsbeispiele für diese Formen von Punktprozessen finden sich in der Versicherungsmathematik. Hier werden zeitliche Punktprozesse und Zählprozesse als Modell genutzt, um das Auftreten von Störfällen oder Katastrophenereignissen zu simulieren [von Dienst et al., 2002]. Der **räumliche Punktprozess**  $X = \{v_1, v_2, \dots, v_n\}$  gibt hingegen die Positionen  $v_i$  an, an denen ein Ereignis auftritt (Abbildung 3.1c). Dieser Prozess stellt die Grundlage der Verfahren zur Objektextraktion in Fernerkundungsdaten dar und findet im Rahmen dieser Arbeit Verwendung.



**Abbildung 3.1.:** Ein zufälliges Ereignis kann mit Punktprozessen  $X$  und Zählprozessen beschrieben werden. (a) Der zeitliche Punktprozess ist die Folge von Zeitpunkten  $s_i$ , an denen das Ereignis auftritt, hier:  $X = \{2001, 2003, 2004, 2007, 2009\}$ . (b) Mit dem Zählprozess wird die Anzahl  $n$  der Ereignisse über die Zeit wiedergegeben. (c) Der räumliche Punktprozess gibt die Positionen des Auftretens  $v_i$  an, hier:  $X = \{(1.5, 0.4), (2.1, 4.5), (2.5, 2.1), (3.8, 3.7), (4.7, 1.5)\}$ .

### 3.1.1. Definition

Ein Punktprozess lässt sich mathematisch mit Begriffen aus der Maßtheorie [Elstrodt, 2010; Wengenroth, 2008] beschreiben. In der Maßtheorie werden *Maßräume* betrachtet, die sich aus dem Tripel  $(\Omega, \mathcal{A}, \mu)$  zusammensetzen. Dabei ist  $\Omega$  eine beliebige nichtleere Menge, auch Grundmenge genannt.  $\mathcal{A}$  beschreibt diejenigen Teilmengen oder Ereignisse von  $\Omega$ , deren Größen gemessen werden sollen und  $\mu$  ist eine Vorschrift, die jeder messbaren Menge ein Maß zuordnet. Das Tupel  $(\Omega, \mathcal{A})$  bildet einen *Messraum*. Als einfaches Beispiel aus dem Bereich der Wahrscheinlichkeitsrechnung sei ein Würfel mit der Grundmenge  $\Omega = \{1, 2, 3, 4, 5, 6\}$  betrachtet. Hierfür können beliebige Teilmengen vorgegeben werden, beispielsweise  $\mathcal{A} = \{\Omega, \emptyset, \{1\}, \{2, 3\}, \{4\}, \{4, 5, 6\}\}$ . Das Maß  $\mu$  ist durch das Wahrscheinlichkeitsmaß  $P : \mathcal{A} \rightarrow [0, 1]$  gegeben und ordnet jedem dieser Ereignisse eine Größe zu, für das Beispiel ergibt sich  $P = \{1, 0, \frac{1}{6}, \frac{1}{3}, \frac{1}{6}, \frac{1}{2}\}$ , der Maßraum wird dann als *Wahrscheinlichkeitsraum* bezeichnet. Im stochastischen Prozess wird ein solcher Wahrscheinlichkeitsraum  $(\Omega, \mathcal{A}, P)$  betrachtet. Darüber hinaus ist der Messraum  $(\mathcal{X}, \mathcal{B})$  bedeutsam, in dem die Beobachtungen erfolgen. Dieser setzt sich aus dem *Zustandsraum*  $\mathcal{X}$ , welcher im Fall von Rasterdaten mit  $\mathcal{X} = \mathbb{R}^2$  gegeben ist, und Teilmengen  $\mathcal{B}$  davon zusammen. Die Zufallsvariable  $\mathbf{X}$ , die den Messraum der Wahrscheinlichkeiten auf den Messraum der Beobachtungen abbildet,

$$\mathbf{X} : (\Omega, \mathcal{A}) \rightarrow (\mathcal{X}, \mathcal{B}), \quad (3.1)$$

heißt **stochastischer Prozess** auf  $(\Omega, \mathcal{A}, P)$  in  $(\mathcal{X}, \mathcal{B})$ . Ist der Zustandsraum  $\mathcal{X}$  zudem endlich oder abzählbar unendlich, so spricht man von einem **Punktprozess**.

Im Folgenden werden räumliche Punktprozesse mit Rasterdaten in Form von Bildern und DGMs als Datengrundlage verwendet. Der Zustandsraum  $\mathcal{X}$  ist daher mit  $\mathcal{X} = \mathbb{R}^2$  gegeben, wobei nur die durch die Bildgrenzen vorgegebene Region  $S = [0 \dots x_{max}] \times [0 \dots y_{max}]$  betrachtet wird. In der Bildana-

lyse werden räumliche Punktprozesse zur Objektextraktion eingesetzt. Hierbei wird eine Vielzahl von Punktprozessen realisiert. Jede einzelne Realisierung setzt sich aus einer Menge von Punkten, einer Punktkonfiguration, zusammen. Das Ziel des markierten Punktprozess ist es, diejenige Konfiguration zu finden, die die größte Übereinstimmung mit einem vorgegebenen Modell aufweist. Um die verschiedenen Realisierungen quantitativ vergleichen zu können, wird ein Maß herangezogen. Für dessen Modellierung liegen unterschiedliche Ansätze vor.

### 3.1.2. Poisson-Punktprozesse

Im einfachsten Fall wird davon ausgegangen, dass die Punkte zufällig im Raum verteilt sind und in keiner Beziehung zueinander stehen. Dann kann der **Poisson-Punktprozess**, der grundlegende Punktprozess in der Maßtheorie, als Modell genutzt werden. Der Poisson-Punktprozess ist über zwei Annahmen definiert:

- Die Anzahl an Punkten  $n(B_1), \dots, n(B_m)$  in disjunkten Teilmengen  $B_1, \dots, B_m$  sind unabhängige Zufallsvariablen.
- Die Anzahl  $n(B_i)$  an Punkten folgt in jeder Teilmenge  $B_i$  einer Poisson-Verteilung. Die Wahrscheinlichkeit  $p(n(B_i))$  für eine bestimmte Anzahl an Punkten ist somit über

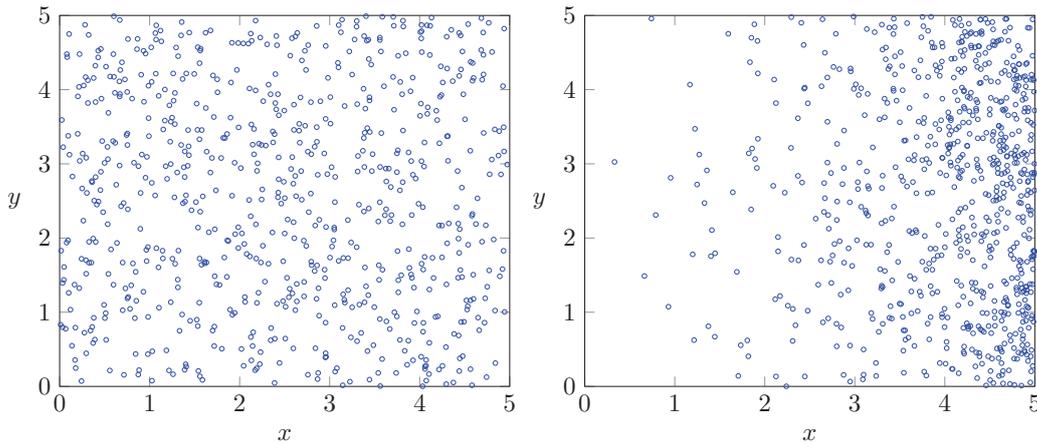
$$p(n(B_i)) = \frac{\lambda(B_i)^{n(B_i)} e^{-\lambda(B_i)}}{n(B_i)!} \quad (3.2)$$

definiert, wobei  $\lambda(B_i)$  dem Erwartungswert der Verteilung für die Teilmenge  $B_i$  entspricht.  $\lambda$  wird auch als *Intensität* bezeichnet, es gilt  $\lambda > 0$ .

Erstere Annahme drückt die Unabhängigkeit der Punkte im Raum aus, welche in keiner Relation zueinander stehen. Mit letzterer Annahme ist ein Maß für den Poisson-Punktprozess in Form von Gleichung 3.2 gegeben. In Abhängigkeit des Modells für die Intensität  $\lambda$  werden zwei Arten von Poisson-Punktprozessen in der Maßtheorie unterschieden. Der *homogene* Poisson-Punktprozess ist dadurch gekennzeichnet, dass die Intensität  $\lambda$  im gesamten Zustandsraum konstant ist. Im Gegensatz dazu wird die Intensität des *inhomogenen* Punktprozesses durch eine Funktion des Ortes definiert. Beispiele für Realisierungen beider Arten von Poisson-Punktprozessen sind in Abbildung 3.2 gegeben. Der Poisson-Punktprozess wird in der Literatur mit der Bezeichnung einer völligen Zufälligkeit in Verbindung gebracht. Für viele praktische Anwendungen ist eine solche Annahme nicht zutreffend, da Abhängigkeiten zwischen den Punkten bestehen. Jedoch ist auch hier der Poisson-Punktprozess relevant, da er in der Regel bei der Definition eines Maßes berücksichtigt wird. Ein komplexerer Punktprozess wird dann in Bezug auf den Poisson-Punktprozess ausgewertet.

### 3.1.3. Gibbs-Punktprozesse

Für viele praktische Anwendungen ist die Annahme nicht zutreffend, dass die Position der Punkte unabhängige Zufallsvariablen sind. Vielmehr ist es erforderlich, die Punkte im Modell untereinander in Bezug zu setzen. Eine Möglichkeit hierfür liefern die **Gibbs-Punktprozesse**, welche u.a. Stoica et al. [2004] und Mallet et al. [2010] verwenden und die auch als Modell in dieser Arbeit genutzt



**Abbildung 3.2.:** Beispiele für einen homogenen (links) und einen inhomogenen Poisson-Punktprozess (rechts). In beiden Fällen beträgt der Erwartungswert  $\lambda = 750$ . Für die Intensität des inhomogenen Poisson-Punktprozesses gilt dabei  $\lambda(x, y) \propto \exp(-x)$ .

werden. Die mathematische Beschreibung der Gibbs-Punktprozesse baut auf der *Gibbs-Energie* auf, welche ursprünglich in der Physik eingeführt wurde, um die Wirkung von Kräften zwischen Teilchen auszudrücken. Jedes Teilchen oder – übertragen auf den Punktprozess – jeder Punkt kann dabei in Wechselwirkung mit benachbarten Punkten treten. Eine Möglichkeit, die Gibbs-Energie  $U(X)$  für die Realisierung eines Punktprozesses  $X$  zu modellieren, ist über

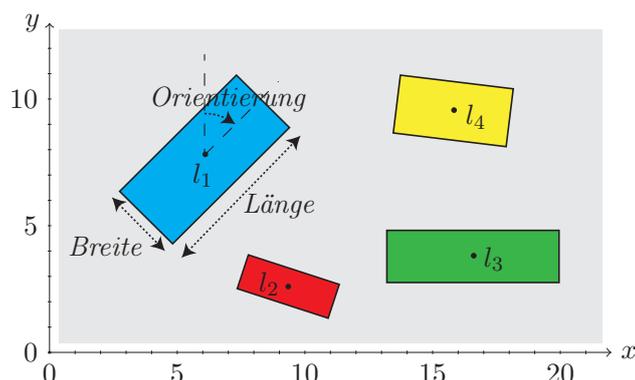
$$U(X) = \beta U_d(X) + (1 - \beta) U_p(X) \quad (3.3)$$

gegeben. Die Gibbs-Energie setzt sich hierbei aus zwei Termen zusammen: (1) dem **Datenterm**  $U_d(X)$ , welcher die Übereinstimmung der Punktkonfiguration mit den Eingangsdaten überprüft und (2) dem **Priorterm**  $U_p(X)$ , der es ermöglicht, A-priori-Wissen über die Punktkonfiguration in das Modell aufzunehmen. So ist es z.B. denkbar, im Datenterm die Grauwerte der Bildpixel, auf denen die Punkte liegen, sowie im Priorterm die euklidischen Distanzen benachbarter Punkte zu analysieren und mit a-priori bekannten Werten oder Verteilungen zu vergleichen. Der relative Einfluss beider Terme ist über  $\beta \in [0, 1]$  reguliert.

Anstelle einer Wahrscheinlichkeit wird als Maß für den Gibbs-Punktprozess die Dichtefunktion  $h(x) \propto \exp(-U(X))$  der Gibbs-Energie verwendet, welche entsprechend der Definitionen in [Descombes, 2012; Nikodym, 1930] in Bezug zu einem Poisson-Punktprozess gesetzt wird. Soll die optimale Punktkonfiguration  $\hat{X}$  aus einer Menge von Punktkonfigurationen  $\Omega$  des Gibbs-Punktprozesses angegeben werden, kann diese durch Minimierung der Gibbs-Energie, d.h.  $\hat{X} = \arg \min_{X \in \Omega} U(X)$ , bestimmt werden. Eine Möglichkeit, wie hierbei der Bezug zum Poisson-Punktprozess hergestellt werden kann, wird in Abschnitt 4.3 aufgezeigt.

### 3.1.4. Markierte Punktprozesse

Die Erweiterung von Punkten und Punktkonfigurationen hin zu Objekten und Objektkonfigurationen gelingt mit Hilfe der **markierten Punktprozesse**. Die Realisierung eines markierten Punktprozesses



**Abbildung 3.3.:** Beispiel für einen markierten Punktprozess, in dem als Modell für die Objekte Rechtecke gewählt sind. Jedes Objekt  $l_i = (v_i, m_i)$  setzt sich aus der Position  $v_i = (x, y)$  und dem Merkmalsvektor  $m_i = [\text{Länge}, \text{Breite}, \text{Orientierung}, \text{Farbe}]$  zusammen. Für Objekt  $l_1$  ergibt sich beispielsweise  $l_1 = [(6, 7.8), 6.4, 3.0, 45^\circ, \text{blau}]$ .

$X = \{l_1, \dots, l_n\}$  ist eine Menge von Objekten  $l_i = (v_i, m_i)$ , wobei sich ein Objekt  $l_i$  aus seiner Position  $v_i$  und einem Merkmalsvektor  $m_i$  zusammensetzt. Im Merkmalsvektor können beliebige Eigenschaften des Objektes modelliert werden. Dies hat den Vorteil, dass eine detailliertere Beschreibung des Objektes möglich ist, welche bei der Objektextraktion in Bilddaten ausgenutzt werden kann. So kann beispielsweise für ein kreisförmiges Objekt die Größe des Radius oder für ein rechteckiges Objekt dessen Seitenlängen und Orientierung in das Modell aufgenommen werden. Des weiteren ist es denkbar, z.B. die Farbe oder den Typ eines Objektes zu definieren. Ein Beispiel für das Modell eines markierten Punktprozesses findet sich in Abbildung 3.3.

## 3.2. Monte-Carlo-Simulationsverfahren

Für den markierten Punktprozess können sich in Abhängigkeit der Definition des Modells und der Anzahl an Merkmalen für die Objekte schnell komplexe Prozesse in hochdimensionalen Räumen ergeben. Um verschiedene Realisierungen hiervon zu erzeugen, verbunden in der Regel mit der Frage nach der optimalen Objektkonfiguration bezüglich eines gegebenen Modells, kommen Simulationsverfahren zum Einsatz. Sehr verbreitete Methoden, die auch in dieser Arbeit Verwendung finden, sind die Monte-Carlo-Simulationsverfahren. Eine ausführliche Beschreibung dieser Thematik findet sich bei Bishop [2006], Liu [2004] und MacKay [2003].

### 3.2.1. Sampling

Während der Simulation wird eine hohe Anzahl von gleichartigen Zufallsexperimenten durchgeführt. Jedes Zufallsexperiment kann dabei als Ziehung einer Stichprobe (Sampling) aufgefasst werden. Die Stichproben können dann genutzt werden, um beispielsweise den Erwartungswert einer Funktion durch Mittelbildung aller Stichproben anzunähern. Eine weitere Anwendungsmöglichkeit stellen Optimierungsaufgaben dar. Das Ziel hierbei ist es, das Optimum einer beliebigen Zielverteilung  $\pi(\cdot)$  zu bestimmen. Da die Zielverteilung häufig in hochdimensionalen Räumen beschrieben ist, ist es in der

Praxis zu rechenintensiv, alle Einträge von  $\pi(\cdot)$  miteinander zu vergleichen, um den optimalen Wert zu bestimmen. Stattdessen werden nur Stichproben  $X_t$  betrachtet und deren Optimum durch

$$\hat{X} = \arg \min_{X_t} \pi(X_t) \quad (3.4)$$

ermittelt<sup>1</sup>.  $t \in \mathcal{T}$  kennzeichnet dabei den Index der Stichprobe. Bei zunehmender Anzahl an Stichproben,  $t \rightarrow \infty$ , konvergiert  $\hat{X}$  gegen das Optimum der Zielfunktion. Es greift das *Gesetz der großen Zahlen*, welches in der Mathematik die Stabilisierung der Ergebnisse eines Zufallsexperimentes bei hinreichender Anzahl an Wiederholungen formuliert. Für das Vorgehen bei der Ziehung der Stichproben liegen unterschiedliche Ansätze vor. Zu den grundlegenden Verfahren zählen das *Rejection Sampling* [von Neumann, 1951] und das *Importance Sampling* [Marshall, 1956]. Wesentlicher Nachteil dieser Ansätze ist jedoch, dass sie sich nicht eignen, um Stichproben aus hochdimensionalen Verteilungen zu ziehen. Hier setzt das *Markov-Chain-Monte-Carlo-Sampling* an.

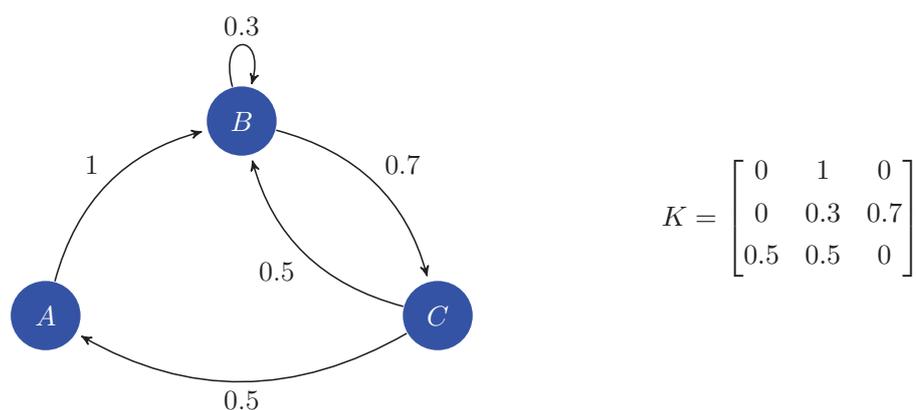
### 3.2.2. Markov-Chain-Monte-Carlo-Sampling

Eine grundlegende und mächtige Klasse von Samplingverfahren ist durch die **Markov-Chain-Monte-Carlo (MCMC)-Methoden** gegeben, welche in der Lage sind, Stichproben auch aus nicht vollständig bekannten Verteilungen und in hochdimensionalen Räumen zu ziehen. Aus diesem Grund haben sie eine breite Anwendung unter anderem in der Statistik, Physik und Informatik erlangt. Für geodätische Fragestellungen finden sich Anwendungsbeispiele bei Kuntzsch et al. [2016]; Huang et al. [2013]; Mayer & Reznik [2007] und Ripperda & Brenner [2006]. Im Zusammenhang mit Punktprozessen wird das MCMC-Sampling häufig als Simulationsverfahren eingesetzt [Geyer & Møller, 1994].

Das prinzipielle Vorgehen der MCMC-Algorithmen liegt darin, Stichproben auf Grundlage einer **Markov-Kette** im Zustandsraum  $\mathcal{X}$  zu erzeugen, um damit die Zielverteilung  $\pi(\cdot)$  anzunähern. Die Markov-Kette setzt sich dabei aus Zufallsvariablen  $X_t$  (auch als *Zustände* bezeichnet) zusammen, wobei  $t$  den Zeitpunkt oder Index in der Markov-Kette kennzeichnet. Im Zusammenhang mit markierten Punktprozessen ist ein Zustand durch eine Objektkonfiguration gegeben. Jeder Zustand wird in der Markov-Kette in Abhängigkeit des vorherigen Zustandes erzeugt, was mit Hilfe einer Übergangswahrscheinlichkeit  $K(X'|X)$  geschieht. Diese gibt für jeden beliebigen Zustand  $X_t = X$  im Zustandsraum die Wahrscheinlichkeit an, in einen beliebigen neuen Zustand  $X_{t+1} = X'$  zu wechseln. Die Übergangswahrscheinlichkeiten können in Form eines Übergangsgraphen oder einer Übergangsmatrix dargestellt werden, ein Beispiel hierfür findet sich in Abbildung 3.4. Bei *homogenen* Markov-Ketten, welche im Folgenden betrachtet werden, sind die Übergangswahrscheinlichkeiten zudem unabhängig vom Zeitpunkt  $t$ , an dem der Übergang in der Markov-Kette erfolgt.

In der Simulation kann bei gegebenen Übergangswahrscheinlichkeiten  $K$  für jeden Zustandswechsel die Zielverteilung  $\pi(\cdot)$  mit Hilfe des vorherigen Zustandes angegeben werden. Die Randverteilung des

<sup>1</sup>Für das Beispiel wird davon ausgegangen, dass es sich bei  $\pi(\cdot)$  um eine Energiefunktion handelt. Das Optimum ist dann durch den minimalen Wert gegeben. Ist  $\pi(\cdot)$  eine Wahrscheinlichkeitsverteilung, wird stattdessen das Funktionsmaximum als Optimum bestimmt.



**Abbildung 3.4.:** Beispiel für einen Übergangsgraphen und eine Übergangsmatrix  $K$  einer Markov-Kette im Zustandsraum  $\mathcal{X} = [A, B, C]$ . Die Pfeile kennzeichnen dabei mögliche Übergänge, die Zahlen geben deren Wahrscheinlichkeit an. So beträgt beispielsweise für  $B$  die Wahrscheinlichkeit 0.3, dass der Zustand beibehalten wird. Mit einer Wahrscheinlichkeit von 0.7 wird auf den Zustand  $C$  übergegangen. Ein Übergang von  $B$  zu  $A$  ist nicht möglich.

Zustandes  $X_{t+1}$  lässt sich dabei über

$$\pi(X_{t+1}) = \pi(X_t) \cdot K \quad (3.5)$$

angeben. Am Beispiel aus Abbildung 3.4 kann dies verdeutlicht werden. Wird die initiale Verteilung zum Zustand  $X_0$  z.B. mit  $\pi(X_0) = [0.2 \ 0.4 \ 0.4]$  vorgegeben, so erhält man für  $\pi(X_1) = \pi(X_0) \cdot K = [0.20 \ 0.52 \ 0.28]$ . Für eine Vielzahl von Iterationen konvergiert das Produkt  $\pi(X_0) \cdot K^t$  gegen  $\pi(\cdot) = [0.17 \ 0.49 \ 0.34]$ . Dasselbe Ergebnis ergibt sich bei Variation von  $\pi(X_0)$ , d.h. die Markov-Kette stabilisiert sich unabhängig des initialen Zustandes. Dies ist genau das Ziel bei Verwendung der MCMC-Algorithmen: eine Markov-Kette in der Art zu konstruieren, dass für  $t \rightarrow \infty$  die Verteilung  $\pi(\cdot)$  gegen die gesuchte Zielverteilung konvergiert und dies unabhängig von der initialen Verteilung. Damit dies erreicht werden kann, müssen folgende Bedingungen erfüllt sein:

- Die Zielverteilung  $\pi(\cdot)$  ist eine *stationäre* Verteilung der Markov-Kette, d.h. eine Verteilung, für die gilt:  $\pi(\cdot) = K \cdot \pi(\cdot)$ .
- Die Markov-Kette ist *ergodisch*, d.h. (1) jeder Zustand in der Markov-Kette kann von jedem anderen Zustand mit positiver Wahrscheinlichkeit erreicht werden (*Irreduzibilität* der Markov-Kette) und (2) die Markov-Kette verharrt in keinem Zyklus (*Aperiodizität* der Markov-Kette).

Eine Möglichkeit, eine Markov-Kette mit diesen Eigenschaften zu konzipieren, liegt in der Definition von Übergangswahrscheinlichkeiten, die die Eigenschaft des *detailed balance* erfüllen. Demnach gilt

$$\pi(X) \cdot K(X'|X) = \pi(X') \cdot K(X|X'), \quad (3.6)$$

d.h. bei Wahl eines beliebigen Zustandes und unter Berücksichtigung der Übergangswahrscheinlichkeiten ist die Wahrscheinlichkeit,  $X$  zu wählen und den Übergang  $X \rightarrow X'$  durchzuführen, genauso groß wie die Wahrscheinlichkeit,  $X'$  zu wählen und den Übergang  $X' \rightarrow X$  durchzuführen.

**Metropolis-Algorithmus:** Ein weitverbreiteter MCMC-Ansatz, der die Bedingung des *detailed balance* erfüllt, ist der von Metropolis et al. [1953] entwickelte Algorithmus. Hierbei werden nach Vorgabe eines initialen Zustands  $X_0$  und unter Berücksichtigung eines Konvergenzkriteriums iterativ die folgenden Schritte durchgeführt:

1. In der Iteration  $t + 1$  wird ein neuer Zustand  $X'$  auf Grundlage des letzten Zustands  $X_t = X$  mit Hilfe des Übergangs  $Q(X'|X)$  erzeugt. Im Folgenden wird dieser Übergang auch als Änderung der Konfiguration oder **Kernel** bezeichnet.
2. Der Quotient  $R$  wird aus der Zielverteilung  $\pi(\cdot)$  für die Zustände  $X'$  und  $X$  gebildet,

$$R = \frac{\pi(X')}{\pi(X)}, \quad (3.7)$$

und über

$$\alpha = \min(1, R). \quad (3.8)$$

eine Akzeptanzwahrscheinlichkeit  $\alpha$  für den neuen Zustand  $X'$  berechnet.

3. Der neue Zustand wird mit der Wahrscheinlichkeit  $\alpha$  angenommen und mit der Wahrscheinlichkeit  $1 - \alpha$  verworfen. In der Praxis wird dies üblicherweise realisiert, indem eine gleichverteilte Zufallszahl  $\gamma \in [0, 1]$  gezogen wird. Sofern  $\gamma < \alpha$ , wird der neue Zustand für die Iteration  $t + 1$  akzeptiert ( $X_{t+1} = X'$ ). Andernfalls wird  $X'$  verworfen und der letzte Zustand beibehalten ( $X_{t+1} = X$ ).

Für den Metropolis-Algorithmus ergeben sich auf diese Weise die Übergangswahrscheinlichkeiten in der Markov-Kette durch

$$K(X'|X) = Q(X'|X) \min\left(1, \frac{\pi(X')}{\pi(X)}\right). \quad (3.9)$$

**Metropolis-Hastings-Algorithmus:** Eine Erweiterung dieses Ansatzes ist in den Arbeiten von Hastings [1970] vorgeschlagen. Hier werden die Übergangswahrscheinlichkeiten um den Quotienten der Kernel ergänzt. Auf diese Weise ist es möglich, nicht-symmetrische Übergänge zu modellieren. Die zuvor aufgeführten Schritte 1. bis 3. werden wie beim Metropolis-Ansatz durchgeführt. Lediglich die Berechnung von  $R$  in Gleichung 3.7 erweitert sich zu

$$R = \frac{\pi(X')}{\pi(X)} \frac{Q(X|X')}{Q(X'|X)}. \quad (3.10)$$

### 3.2.3. Reversible-Jump-Markov-Chain-Monte-Carlo-Sampling

Die bisher aufgezeigten MCMC-Ansätze gehen von einem festen Modell für das zu untersuchende Problem aus, bei dem die Anzahl an Parametern in jedem Zustand konstant ist. Bezogen auf die Optimierung bei markierten Punktprozessen bedeutet dies, dass die Objektanzahl im gesamten Prozess konstant sein muss, was die Anwendung wenig flexibel macht. Eine Möglichkeit, diese Einschränkung zu umgehen, liefert das **Reversible-Jump-Markov-Chain-Monte-Carlo (RJMCMC)-Sampling**, welches auf die Arbeiten von Green [1995] zurückgeht. Anschauliche Beispiele hierzu finden sich bei Smith [2007], Andrieu et al. [2003] und Richardson & Green [1997].

Mit dem von Green [1995] vorgeschlagenen RJMCMC-Algorithmus können unterschiedliche Modelle zur Beschreibung des Objektes herangezogen werden. So ist es möglich, Zustände innerhalb der Markov-Kette zu erzeugen und miteinander zu vergleichen, die in Zustandsräumen unterschiedlicher Dimension vorliegen. Ein anschauliches Beispiel hierzu findet sich in Abbildung 3.5. Um zwei Modelle miteinander zu vergleichen, wird das eine Modell in den Zustandsraum des anderen transformiert. Dies gelingt mit Hilfe einer Übergangsfunktion  $f_{X \rightarrow X'}$ , die für den Übergang  $X \rightarrow X'$  problemabhängig definiert werden muss. Zudem werden Hilfsvariablen  $h$  und  $h'$  für die Dimensionsanpassung eingeführt. Der Übergang von Zustand  $X$  zu Zustand  $X'$  lässt sich dann mit  $(X', h') = f_{X \rightarrow X'}(X, h)$  beschreiben. Damit die Bedingung des *detailed balance* (Gleichung 3.6) erfüllt ist, ist es zudem erforderlich, dass auch die reversible Übergangsfunktion  $f_{X' \rightarrow X}$  definiert ist und eine Rückkehr in den vorherigen Zustand möglich ist. In der Praxis wird dies erreicht, indem Paare von reversiblen Änderungen modelliert werden. So stellt beispielsweise die Änderung "ein Objekt hinzufügen" im markierten Punktprozess die reversible Änderung von "ein Objekt entfernen" dar. Gleichung 3.10 der Metropolis-Hastings-Methode erweitert sich dann zu

$$R = \frac{\pi(X')}{\pi(X)} \frac{p_{Q_i^r}}{p_{Q_i}} \frac{Q(X, h|X', h')}{Q(X', h'|X, h)} \left| \det \left( \frac{\partial f_{X \rightarrow X'}(X, h)}{\partial(X, h)} \right) \right| \quad (3.11)$$

und wird als **Green-Ratio** bezeichnet. Hierbei entsprechen  $\pi(X')$  und  $\pi(X)$  den Werten der Zielverteilung im vorherigen Zustand  $X$  und im neuen Zustand  $X'$ . Die Vorschlagswahrscheinlichkeiten für die Übergänge  $X \rightarrow X'$  und  $X' \rightarrow X$  sind mit  $Q(X, h|X', h')$  und  $Q(X', h'|X, h)$  gegeben. Dabei werden die Hilfsvariablen  $h$  und  $h'$  berücksichtigt, die für die Dimensionsanpassung eingeführt sind. Mit  $p_{Q_i^r}$  und  $p_{Q_i}$  wird die Wahrscheinlichkeit bezeichnet, Kernel  $Q_i$  bzw. dessen reversiblen Kernel  $Q_i^r$  auszuwählen. Der Ausdruck  $\det \left( \frac{\partial f_{X \rightarrow X'}(X, h)}{\partial(X, h)} \right)$  entspricht der Jakobi-Determinanten der Übergangsfunktion  $f_{X \rightarrow X'}$ . Die Jakobi-Determinante kann mit

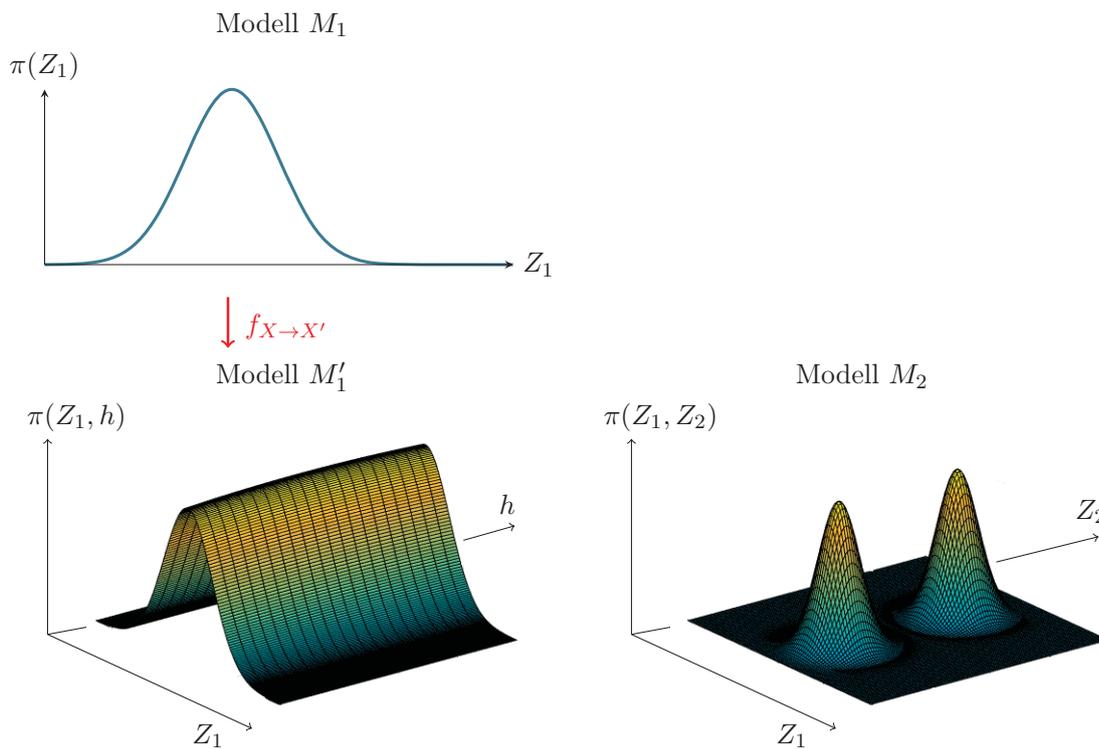
$$\det \left( \frac{\partial f_{X \rightarrow X'}(X, h)}{\partial(X, h)} \right) = \det \left( \frac{\partial(X', h')}{\partial(X, h)} \right) = \det \begin{pmatrix} \frac{\partial Z'_1}{\partial Z_1} & \cdots & \frac{\partial Z'_1}{\partial Z_m} & \frac{\partial Z'_1}{\partial h} \\ \vdots & \ddots & \vdots & \vdots \\ \frac{\partial Z'_{m'}}{\partial Z_1} & \cdots & \frac{\partial Z'_{m'}}{\partial Z_m} & \frac{\partial Z'_{m'}}{\partial h} \\ \frac{\partial h'}{\partial Z_1} & \cdots & \frac{\partial h'}{\partial Z_m} & \frac{\partial h'}{\partial h} \end{pmatrix} \quad (3.12)$$

bestimmt werden, wobei  $Z'_1, \dots, Z'_{m'}$  die Parameter im Zustand  $X'$  und  $Z_1, \dots, Z_m$  die Parameter im vorherigen Zustand  $X$  angeben.

### 3.2.4. Simulated Annealing

In der Praxis wird das RJMCMC-Sampling häufig mit einem *Simulated Annealing*-Ansatz [Kirkpatrick et al., 1983], einem heuristischen Optimierungsverfahren, kombiniert. Im Simulationsansatz wird dann ein Temperaturparameter  $T_t$  eingeführt und die Zielverteilung in Abhängigkeit hiervon über

$$\pi_t(\cdot) := \lim_{t \rightarrow \infty} \pi^{\frac{1}{T_t}}(\cdot). \quad (3.13)$$



**Abbildung 3.5.:** Beispiel für die Anwendung eines RJMCMC-Verfahrens, bei dem die Verteilungen zweier Modelle  $M_1$  und  $M_2$  verglichen werden sollen. Da die Verteilungen in unterschiedlichen Dimensionen vorliegen, wird die 1D-Verteilung unter Ausnutzung einer Hilfsvariablen  $h$  mit Hilfe der Übergangsfunktion  $f_{X \rightarrow X'}$  in eine 2D-Verteilung (Modell  $M_1'$ ) überführt. Anschließend kann ein Vergleich beider Verteilungen über ein gemeinsames Maß, wie z.B. dem Flächeninhalt, erfolgen (Beispiel in Anlehnung an [Andrieu et al., 2003]).

angegeben. Die Temperatur nimmt mit zunehmender Iteration ab, es gilt  $\lim_{t \rightarrow \infty} T_t = 0$ . Auf diese Weise ist es möglich, zu Beginn der Markov-Kette große Sprünge zwischen den Zuständen zuzulassen und den Zustandsraum weitläufig zu erkunden. Beim Abkühlen der Temperatur werden dann nur noch zunehmend kleinere Zustandsänderungen zugelassen. Sofern ein logarithmisches Abkühlungsverfahren bei diesem Vorgehen gewählt wird, ist die Konvergenz zum globalen Optimum in der Optimierungsaufgabe garantiert. In der Praxis werden stattdessen üblicherweise geometrische, lineare oder exponentielle Abkühlungsfunktionen eingesetzt. Hierbei ist die Konvergenz nicht garantiert, jedoch sind diese Verfahren schneller und liefern in der Regel eine gute Approximation [Tournaire et al., 2010; Salamon et al., 2002]. Ein Konvergenzkriterium legt dabei fest, wann die Simulation abgebrochen werden soll [Siarry et al., 1997; Romeo & Sangiovanni-Vincentelli, 1991]. Dies kann beispielsweise über die Anzahl an Iterationen oder das Änderungsverhalten der Parameter definiert werden.

### 3.3. Graphentheorie

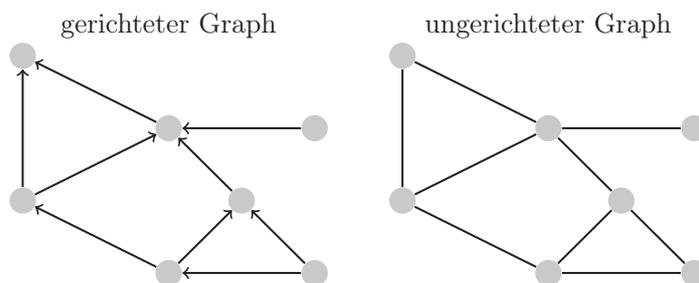
Viele praktische Anwendungen in den unterschiedlichsten Disziplinen lassen sich anschaulich mit Hilfe von Diagrammen darstellen, welche sich aus einer Menge von Knoten, sowie Kanten, die einige Knoten

untereinander verbinden, zusammensetzen. Letztere kennzeichnen Relationen in der untersuchten Anwendung. Eine mathematische Beschreibung hierfür liefert die Graphentheorie. Für weiterführende Literatur in diesem Gebiet sei auf Diestel [2010] und Bondy & Murty [2008] verwiesen.

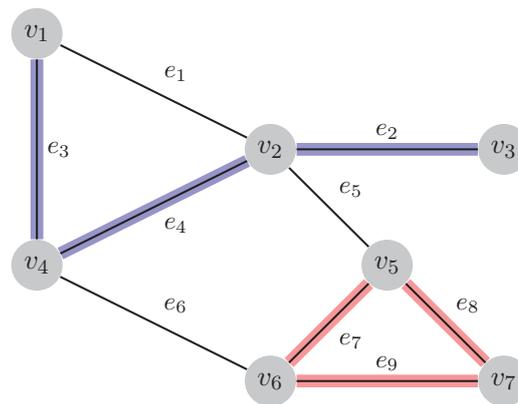
Ein Graph  $G$  ist ein Paar  $(V, E)$ , das sich aus einer Menge  $V$  von *Knoten* und einer Menge  $E$  von *Kanten* zusammensetzt. Der Graph ist *gerichtet*, wenn alle Knotenpaare, die eine Kante beschreiben, geordnet sind (Abbildung 3.6). Jede Kante kann dann nur in einer Richtung durchlaufen werden. Im Gegensatz dazu weist ein *ungerichteter* Graph ungeordnete Knotenpaare auf (Abbildung 3.6). Im Folgenden werden ausschließlich ungerichtete Graphen betrachtet.

Eine Kante und ein Knoten werden im Graphen als *inzident* bezeichnet, sofern der Knoten ein Endpunkt der Kante ist. Im Graph in Abbildung 3.7 sind beispielsweise Knoten  $v_1$  und Kante  $e_3$  inzident. Die Anzahl der inzidenten Kanten eines Knotens gibt den *Grad*  $k$  eines Knotens an, so haben Knoten  $v_1$  und  $v_2$  den Grad  $k_{v_1} = 2$  bzw.  $k_{v_2} = 4$ . Sind zwei Knoten benachbart und über eine Kante miteinander verbunden, wie z.B. Knoten  $v_1$  und  $v_4$ , so spricht man davon, dass die Knoten *adjazent* sind. Eine Möglichkeit, den Graphen zu repräsentieren, ist neben der graphischen Darstellung durch die *Adjazenzmatrix* gegeben. Hierbei handelt es sich um eine  $n \times n$  Matrix, wobei  $n$  die Anzahl der Knoten angibt. In der Matrix betragen die Einträge Eins, sofern die beiden zu diesem Eintrag korrespondierenden Knoten mit einer Kante verbunden sind, in allen anderen Fällen sind die Einträge Null. Eine kompaktere Repräsentation der Verbundenheit der Knoten ist über die *Adjazenzliste* gegeben, in der für jeden Knoten die Menge an adjazenten Knoten aufgelistet ist. Für beide Formen ist ein Beispiel in Abbildung 3.7 gegeben.

Eine Folge von Knoten, in welcher aufeinanderfolgende Knoten jeweils adjazent sind, wird als *Weg* bezeichnet. So ist die in Abbildung 3.7 blau markierte Folge  $\{v_1, v_4, v_2, v_3\}$  ein Weg im Graphen. Sind Start- und Endknoten des Weges identisch, handelt es sich um einen *Zyklus*, was für den rot markierten Weg  $\{v_5, v_6, v_7\}$  gilt. Der Graph ist *planar*, wenn er in einer Ebene gezeichnet werden kann, ohne dass sich Kanten schneiden. Eine spezielle Art eines Graphen ist durch den **Baum** gegeben (siehe Abbildung 3.8). Ein Baum ist ein *azyklischer* Graph, d.h. ein Graph der keine Zyklen enthält. Zudem erfüllt ein Baum die Eigenschaft der Planarität. Ein Graph, der sich aus mehreren Bäumen zusammensetzt, wird als **Wald** bezeichnet. In dieser Arbeit wird ein Wald als Modell genutzt, um Liniennetze und im Speziellen Flussnetze in Rasterdaten zu beschreiben. Durch Wahl einer Baumstruktur lässt sich die Charakteristik von Flüssen, welche sich in der Regel in viele Seitenarme verästeln, gut abbilden.

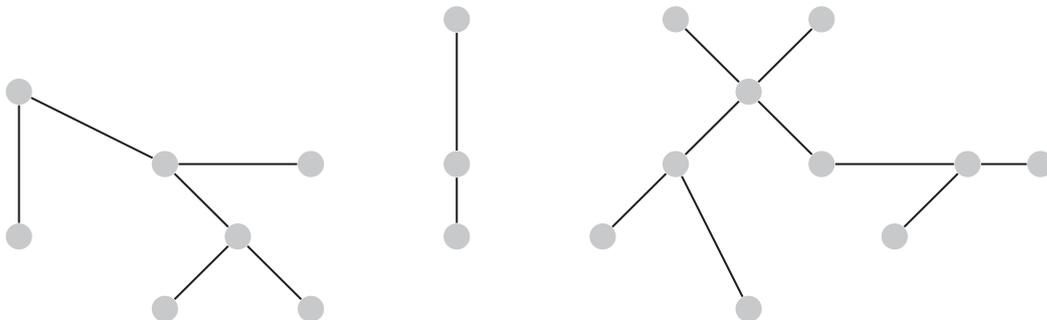


**Abbildung 3.6.:** Im gerichteten Graph können die Kanten nur in einer Richtung durchlaufen werden. Im ungerichteten Graph ist die Reihenfolge von Start- und Endknoten einer Kante nicht relevant.



	Adjazenzmatrix							Adjazenzliste
	$v_1$	$v_2$	$v_3$	$v_4$	$v_5$	$v_6$	$v_7$	
$v_1$	0	1	0	1	0	0	0	$v_1$ : $v_2, v_4$
$v_2$	1	0	1	1	1	0	0	$v_2$ : $v_1, v_3, v_4, v_5$
$v_3$	0	1	0	0	0	0	0	$v_3$ : $v_2$
$v_4$	1	1	0	0	0	1	0	$v_4$ : $v_1, v_2, v_6$
$v_5$	0	1	0	0	0	1	1	$v_5$ : $v_2, v_6, v_7$
$v_6$	0	0	0	1	1	0	1	$v_6$ : $v_4, v_5, v_7$
$v_7$	0	0	0	0	1	1	0	$v_7$ : $v_5, v_6$

**Abbildung 3.7.:** Ein Graph setzt sich aus Knoten  $v_i$  und aus Kanten  $e_i$  zusammen. Die Nachbarschaft (Adjazenz) von Knoten kann in Form einer Adjazenzmatrix oder einer Adjazenzliste angegeben werden.



**Abbildung 3.8.:** Ein Wald setzt sich aus einzelnen Bäumen zusammen. Jeder Baum ist dadurch gekennzeichnet, dass kein Zyklus im Graph enthalten ist.

---

## 4. Neue Methode für die Extraktion von Liniennetzen

In diesem Kapitel wird das für die Extraktion von Liniennetzen neu entwickelte und auf markierten Punktprozessen basierende Verfahren beschrieben. Die Suche nach der optimalen Objektkonfiguration wird über ein RJMCMC-Sampling gekoppelt mit einem Simulated Annealing-Ansatz durchgeführt. Im Folgenden wird zunächst das Objektmodell definiert, das für die Extraktion des Liniennetzes gewählt wurde (Abschnitt 4.1). Anschließend wird das Modell für die Energiefunktion erläutert, für welche im RJMCMC-Sampling das Optimum ermittelt wird (Abschnitt 4.2). Um unterschiedliche Objektkonfigurationen während des Samplings zu erzeugen, wurden verschiedene Arten von Änderungen entwickelt, die Abschnitt 4.3 beschreibt. Zwei Erweiterungen zur Beschleunigung des Sampling-Verfahrens sowie der konzeptionelle Ablauf der Methode werden in den Abschnitten 4.4 und 4.5 vorgestellt. Abschließend erfolgt eine Diskussion des Ansatzes (Abschnitt 4.6).

### 4.1. Objektmodell

Viele auf markierten Punktprozessen basierende Ansätze lassen Informationen über die Nachbarschaft von Objekten in das Modell einfließen. Üblicherweise geschieht dies über die Energiefunktion, indem

- (1) Objekte mit bestimmten Distanzen zueinander bevorzugt oder aber bestraft werden [Chai et al., 2016; Tournaire & Paparoditis, 2009; Perrin et al., 2006; Lacoste et al., 2006],
- (2) ähnliche Merkmale für Objekte in der Nachbarschaft bevorzugt werden [Börcs & Benedek, 2015; Verdié & Lafarge, 2014],
- (3) Bedingungen für die Ausrichtung von benachbarten Objekten modelliert werden [Benedek et al., 2012; Stoica et al., 2004; Descombes & Zerubia, 2002].

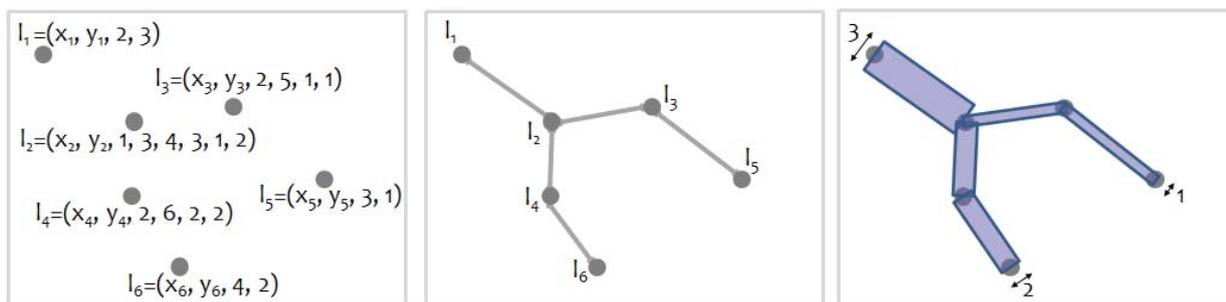
Eine weitere Möglichkeit für das Einbinden von Nachbarschaftsrelationen in den markierten Punktprozess liegt darin, Objekte bevorzugt in der Nähe bereits vorhandener Objekte vorzuschlagen und entsprechende Modelle für die Änderungen der Objektkonfiguration aufzustellen [Tournaire & Paparoditis, 2009; Ortner et al., 2008; Perrin et al., 2006; Lacoste et al., 2005; Descombes & Zerubia, 2002].

Im Folgenden wird eine andere Herangehensweise gewählt, um das Treffen heuristischer Annahmen – beispielsweise über bevorzugte Distanzen – zu umgehen. Im Gegensatz zu den aufgezeigten Ansätzen wird die Nachbarschaft direkt im Zustandsraum der Merkmale modelliert. Hierfür wird jeder Punkt in der Konfiguration mit einer Menge von Punkten verknüpft, bei welchen es sich um die benachbarten

Punkte handelt. Auf diese Weise lässt sich die Punktconfiguration eindeutig mit Hilfe eines **Graphen** beschreiben. Die Knoten des Graphen entsprechen dabei den Punkten in der Punktconfiguration, während die Kanten Paaren von benachbarten Punkten zugeordnet werden können. Da die Kernanwendung des entwickelten Verfahrens die Extraktion von Gewässernetzen ist, wird an den Graphen die Bedingung gestellt, dass er die Struktur von Bäumen aufweist. Dies bringt den Vorteil mit sich, dass das Fließen des Wassers in nur einer Richtung garantiert werden kann, da Zyklen im Graphen ausgeschlossen werden.

Als Objektmodell wird eine Menge von Bäumen, ein **Wald**, eingeführt. Für den damit verbundenen markierten Punktprozess wird im Folgenden die Bezeichnung **Forest Point Process** gewählt. Ein *Forest Point Process* ist ein markierter Punktprozess, in dem jeder Punkt mit einer Menge von Punkten auf eine solche Weise verknüpft ist, dass der Graph jeder Punktconfiguration einen Wald beschreibt. Der Graph ist somit auf die Form eines ungerichteten, azyklischen, planaren Graphen beschränkt. Im *Forest Point Process* ist jeder Punkt über eine Menge von Variablen  $l = (v, i_1, \dots, i_k, w_1, \dots, w_k)$  definiert, wobei  $v = (x, y)$  die Position des Punktes in den Rasterdaten angibt.  $i_1, \dots, i_k$  sind die Indizes der  $k$  adjazenten Punkte, welche aus der Adjazenzliste des Graphen entnommen werden können, und die Parameter  $w_1, \dots, w_k$  geben die Breiten der inzidenten Kanten an (siehe Abbildung 4.1). Hierbei ist anzumerken, dass in der vorgenommenen Definition die Breite einer Kante für beide adjazenten Knoten gespeichert ist. In der praktischen Umsetzung wurde diese Redundanz durch die Implementierung einer Graphstruktur, in der jeder Kante eine Breite zugeordnet wurde, umgangen.

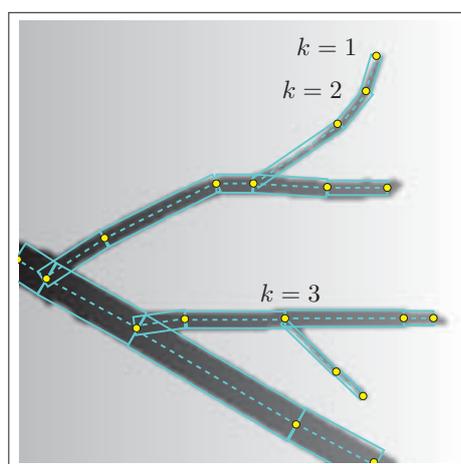
Die gesamte Objektkonfiguration  $X$  wird durch den Wald gebildet und ergibt sich über  $X = \{l_1, \dots, l_n\}$ . Hierbei kennzeichnet  $n$  die Anzahl an Punkten, die in jeder Iteration variieren kann. Für die Kanten im Wald wird im Folgenden die Bezeichnung  $e$  gewählt. Da die Kanten über eine Breite verfügen und somit eine Fläche beschreiben, wird zukünftig der Begriff Liniensegment synonym für eine Kante verwendet. Jedem Punkt kann in Abhängigkeit seines Knotengrads eine Bedeutung im Liniennetz zugesprochen werden. Beträgt der Grad eines Knotens  $k = 1$ , handelt es sich um einen Endpunkt. Für  $k > 1$  entspricht der Knoten einem Punkt innerhalb des Netzes, welcher durch eine



**Abbildung 4.1.:** Links: Im *Forest Point Process* wird eine Konfiguration von Punkten generiert, in der jeder Punkt  $l$  mit den Indizes  $i$  der adjazenten Punkte verknüpft ist (z.B. für Punkt  $l_3$ :  $i_1 = 2$  und  $i_2 = 5$ ). Zudem trägt jeder Punkt die Information über die Breite  $w$  der inzidenten Kanten (z.B. für Punkt  $l_3$ :  $w = 1$  für die Kante  $\{l_2, l_3\}$  und  $w = 1$  für die Kante  $\{l_3, l_5\}$ ). Mitte: Jede Punktconfiguration kann auf diese Weise mit einem azyklischen, planaren Graphen eindeutig beschrieben werden. Rechts: Das resultierende Netz ist ein Baum oder eine Menge von Bäumen, die durch verbundene Liniensegmente repräsentiert sind, wobei jedes Liniensegment eine spezifische Breite hat.

Richtungsänderung ( $k = 2$ ) oder das Zusammenkommen mehrerer Zweige des Liniennetzes ( $k > 2$ ) erforderlich ist (Abbildung 4.2).

Darüber hinaus werden drei Bedingungen an den Wald geknüpft und im *Forest Point Process* modelliert. Zum einen wird gefordert, dass jeder Knoten mindestens einen adjazenten Knoten aufweisen muss, d.h. isolierte Knoten vom Grad  $k = 0$  werden ausgeschlossen. Zum anderen wird gefordert, dass sich die Kanten im Objektraum nicht schneiden dürfen, ohne dass an ihrem Schnittpunkt ein Knoten vorliegt. Zudem dürfen zwei Knoten im Graph nicht dieselben Koordinaten aufweisen. Diese Bedingungen werden bei der Konstruktion des Waldes berücksichtigt (siehe Abschnitt 4.3).



**Abbildung 4.2.:** Je nach Grad eines Knotens entspricht dieser einem Endpunkt im Liniennetz ( $k = 1$ ), einem Punkt, an dem sich die Richtung ändert ( $k = 2$ ) oder einem Punkt, an dem mehrere Zweige zusammenkommen ( $k > 2$ ).

## 4.2. Energiefunktion

Für die Evaluation jeder Konfiguration wird im *Forest Point Process* das Modell einer Gibbs-Energie gewählt, welche sich aus einem Datenterm, der die Übereinstimmung der Objektkonfiguration mit den Eingangsdaten überprüft, sowie einem Priorterm zusammensetzt, über den Vorwissen bezüglich der Konfiguration eingebunden werden kann (siehe Gleichung 3.3). Das Ziel des gewählten Verfahrens ist es, das globale Minimum der Energiefunktion zu bestimmen. Objektkonfigurationen, die das Liniennetz geeignet beschreiben, sollen dazu führen, dass der Wert der Energiefunktion kleiner wird. Umgekehrt kann durch eine Bestrafung ungeeigneter Konfigurationen erreicht werden, dass derartige Konfigurationen im Sampling-Prozess weniger wahrscheinlich angenommen werden. Insgesamt wird im Folgenden die Energiefunktion aus fünf Termen zusammengesetzt,

$$U(X) = \beta \underbrace{(U_g(X) + U_h(X))}_{\text{Datenterm } U_d} + (1 - \beta) \underbrace{(U_o(X) + U_c(X) + U_f(X))}_{\text{Priorterm } U_p}, \quad (4.1)$$

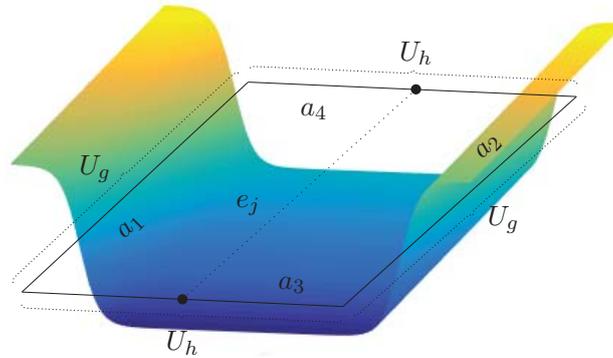
wobei jeder Term eine spezielle Eigenschaft des Liniennetzes beschreibt. Durch Variation des Faktors  $\beta$  kann entweder dem Daten- oder dem Priorterm ein höheres Gewicht beigemessen werden.

### 4.2.1. Datenterm

Im Datenterm wird die Konsistenz der Objektkonfiguration mit den Eingangsdaten überprüft. Das gewählte Modell hierfür ist motiviert durch die Kernanwendung dieser Arbeit: der Extraktion von Fluss- und Prielnetzen in einem DGM. Gewässernetze sind durch lokal geringere Höhen als ihre Umgebung gekennzeichnet. Unter Vernachlässigung von Wellen und großen Objekten im Flussbett, wie beispielsweise Steinen, weist die Wasseroberfläche lokal homogene Höhenwerte auf. An beiden Uferseiten steigt das Gelände an (siehe Abbildung 4.3). Die angeführten Charakteristiken von Flüssen werden im Datenterm der Energiefunktion durch

$$U_d(X) = U_g(X) + U_h(X) \quad (4.2)$$

abgebildet. Der Term  $U_g$  berücksichtigt dabei den Anstieg des Geländes an beiden Uferseiten, über den Term  $U_h$  wird die Ebenheit der Wasseroberfläche beschrieben.

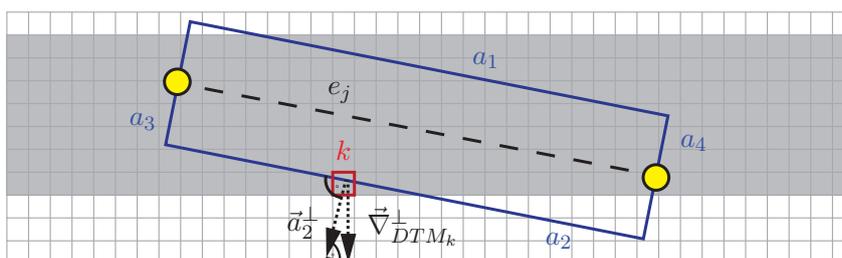


**Abbildung 4.3.:** 3D-Modell eines Flussquerschnitts. Für jedes Liniensegment  $e_j$  werden die Gradientenbeträge entlang der Ränder  $a_1, a_2$  im Datenterm  $U_g$  ausgewertet. Die Homogenität der Höhenwerte wird entlang der Ränder  $a_3, a_4$  im Datenterm  $U_h$  berechnet.

**Hohe Gradientenbeträge an den Rändern:** Um den Anstieg des Geländes am Gewässerrand im Modell abzubilden, werden die Gradienten im DGM betrachtet. Damit ein Liniensegment das Liniennetz geeignet beschreibt, müssen hohe Gradientenbeträge an dessen Rändern vorhanden sein, was durch

$$U_g(X) = \sum_{e_j \in X} \left( c_1 - \sum_{m=1}^2 \frac{1}{n_{a_m}} \sum_{k=1}^{n_{a_m}} \nabla_{DTM_k}^\perp \right). \quad (4.3)$$

modelliert ist. Hierbei entspricht  $\nabla_{DTM_k}^\perp = \langle \vec{\nabla}_{DTM_k}, \vec{a}_m^\perp \rangle$  der Komponente des Gradienten im DGM in Richtung des nach außen weisenden Normalenvektors  $\vec{a}_m^\perp$  des Segmentrandes der Kante  $e_j$  (siehe Abbildung 4.4). Die Gradientenbeträge werden entlang der Segmentränder  $a_1$  und  $a_2$  aufsummiert, da diese potentiell den Gewässerrändern entsprechen. Die Summe ist über alle Pixel  $k$  entlang der Segmentränder gebildet, wobei der Gradientenbetrag jedes Pixels mit gleichem Gewicht eingeht.  $n_{a_m}$  entspricht der Anzahl an Pixeln entlang des Randes. Um sicherzustellen, dass sich die Energie nur verringert, sobald die Summe über einem vorgegebenen Wert liegt, wird eine Konstante  $c_1 \geq 0$  eingeführt. Auf diese Weise kann die Wahrscheinlichkeit verringert werden, dass ein Liniensegment im



**Abbildung 4.4.:** Die Gradientenbeträge in Richtung des Normalenvektors der Segmentränder werden entlang  $a_1$  und  $a_2$  für alle Pixel aufsummiert.

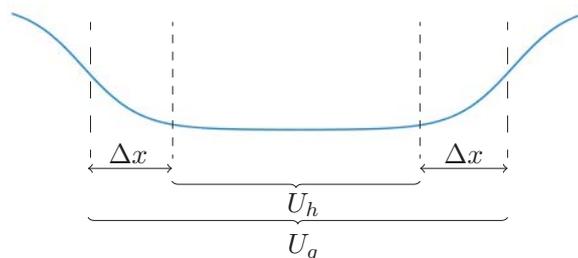
homogenen Gelände – in welchem die Gradientenbeträge nahezu Null betragen und die Datenenergie weder signifikant reduzieren noch signifikant erhöhen – im Sampling-Prozess angenommen wird.

**Homogenität der Höhen:** Um zu überprüfen, ob die Höhen im Flussbett homogen sind, d.h. ähnliche Werte aufweisen, werden diese mittels

$$U_h(X) = p_h \cdot \sum_{e_j \in X} \max \left( 0, -c_2 + \sum_{m=3}^4 \sigma_z(a_m) \right), \quad (4.4)$$

ausgewertet. Dabei wird nicht die gesamte Fläche des Liniensegments betrachtet, sondern lediglich die Höhen entlang der senkrecht zur Fließrichtung verlaufenden Ränder  $a_3$  und  $a_4$  (siehe Abbildung 4.3). Für diese wird gefordert, dass die Standardabweichung der Höhen  $\sigma_z(a_m)$  entlang der Ränder gering ist. Um weniger anfällig gegenüber Rauschen in den Daten zu sein, ist eine Konstante  $c_2 \geq 0$  eingeführt. Über den Faktor  $p_h \in [0, \infty)$  wird der Term gewichtet.

In dem Modell wird davon ausgegangen, dass Gewässer im Querschnitt wie in Abbildung 4.5 approximiert werden können. Hier kann das Problem auftreten, dass die Datenterme  $U_g$  und  $U_h$  unterschiedliche Segmente als bestes Ergebnis im Sampling ausgeben. Während  $U_g$  diejenigen Segmente als geeignet bewertet, deren Ränder mit den höchsten Gradientenbeträgen übereinstimmen, wird  $U_h$  etwas schmalere Segmente bevorzugen, für die homogene Höhenwerte im Querprofil vorliegen. Um diesen Konflikt zu umgehen, wird ein freier Parameter  $\Delta x$  eingeführt, der einer vom Nutzer frei zu wählenden Strecke auf beiden Seiten des Querprofils entspricht, entlang derer die Höhen zur Berechnung des Datenterms  $U_h$  vernachlässigt werden (Abbildung 4.5).



**Abbildung 4.5.:** Um dem Widerspruch im Datenterm zu begegnen, wird der Homogenitätsterm der Höhen  $U_h$  nicht für das gesamte Querprofil ausgewertet. Die Höhen entlang  $\Delta x$  werden für die Berechnung vernachlässigt.

### 4.2.2. Priorterm

Mit Hilfe des Priorterms kann Vorwissen über das Netz im Modell eingebunden werden. Auf diese Weise lassen sich bestimmte Wälder im Ergebnis bevorzugen. Für markierte Punktprozesse hat sich gezeigt, dass es sinnvoll ist, die Überlappung von einzelnen Objekten zu bestrafen (siehe Abschnitt 2.2), was im Folgenden aufgegriffen wird. Bei der Modellierung eines Liniennetzes ist es zudem angebracht, unverbundene Graphen zu bestrafen, um die Anzahl an Bäumen im Wald gering zu halten. Darüber hinaus wird auf die Besonderheit von Flussnetzen eingegangen, indem physikalisches Wissen über die Fließrichtung des Wassers eingebunden wird. Der Priorterm setzt sich daher aus drei Termen zusammen,

$$U_p(X) = U_o(X) + U_c(X) + U_f(X), \quad (4.5)$$

wobei jeder der Terme eine der genannten Eigenschaften der gewünschten Objektkonfiguration beschreibt.

**Nicht-überlappende Liniensegmente:** Um zu verhindern, dass sich eine Vielzahl von Objekten in den Bereichen der Eingangsdaten anhäufen, in denen der Datenterm zu geringen Werten der Energiefunktion führt, wird die Überlappung der Liniensegmente im Wald bestraft. Hierfür wird die Überlappungsfläche  $A_{ij}$  der Kanten  $e_i$  und  $e_j$  sowie deren relative Überlappungsflächen  $\frac{A}{A(e_i)}$  und  $\frac{A}{A(e_j)}$  berechnet. Der korrespondierende Energieterm ergibt sich dann über

$$U_o(X) = p_o \sum_{i \neq j} \max \left( \frac{A}{A(e_i)}, \frac{A}{A(e_j)} \right), \quad (4.6)$$

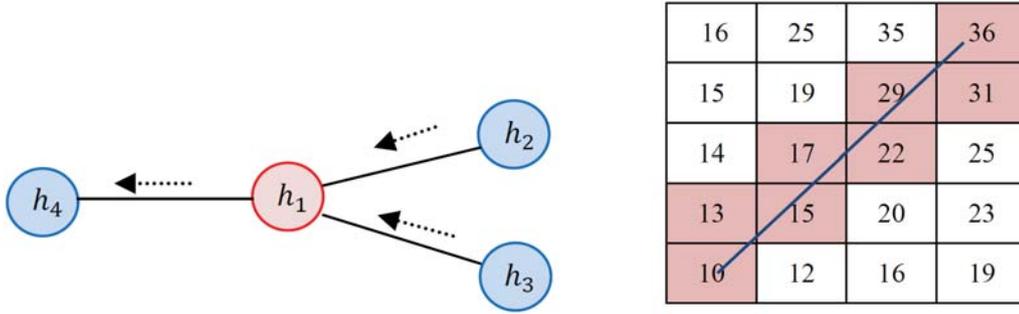
wobei nur die größere der Überlappungsflächen zweier Kanten  $e_i$  und  $e_j$  in die Summe eingeht. Die Flächen werden mit dem Bestrafungsfaktor  $p_o \in [0, \infty)$  gewichtet.

**Verbundenheit des Graphen:** Liniennetze wie Gewässernetze sind dadurch gekennzeichnet, dass das Netz zumeist komplett verbunden ist. Ausnahmen treten auf, sofern ein Gebirgsgrat vorliegt oder der Bildausschnitt nur Teile des Netzes umfasst. Dennoch wird auch in diesen Fällen das Netz aus einer geringen Menge von Bäumen bestehen. Um eine Verbundenheit des Graphen zu bevorzugen, wird die Konfiguration über

$$U_c(X_t) = p_c \cdot (n_{sg} - 1) \quad (4.7)$$

bewertet.  $n_{sg}$  entspricht dabei der Anzahl an Bäumen im Wald,  $p_c \in [0, \infty)$  gibt das Gewicht dieses Terms an.

**Physikalische Konsistenz des Netzes:** Für Gewässernetze gilt, dass das Wasser in der Regel bergab fließt. Das Wissen bezüglich der Fließrichtung des Wassers wird im Modell in Form von zwei Kriterien berücksichtigt, welche in Abbildung 4.6 veranschaulicht sind. Zum einen wird gefordert, dass jeder Knoten mit genau einem Knoten verbunden ist, der über eine geringere Höhe im DGM verfügt, aber mit einer beliebigen Anzahl von Knoten mit größeren Höhenwerten. Es wird dabei Kauf genommen, dass die Modellierung eines Deltas oder einer Insel nicht abgedeckt werden kann. Des weiteren wird gefordert, dass alle Pixel entlang der Mittelachse einer Kante denselben Trend in den Daten zeigen, d.h. von einem Knoten zu seinem adjazenten Knoten sollen alle Höhenwerte zu- bzw. abnehmen. Andernfalls erfolgt eine Bestrafung der Kante. Um weniger anfällig gegenüber Rauschen



**Abbildung 4.6.:** Um die physikalische Konsistenz des Netzes im Priorterm zu berücksichtigen, werden zwei Kriterien bezüglich der Fließrichtung eingeführt. (1) Ein Knoten muss genau einen Nachbarn mit einer geringeren Höhe aufweisen, was für den Beispielgraphen (links) erfüllt ist. Es gilt:  $h_4 < h_1$  und  $h_2 > h_1$ ,  $h_3 > h_1$ ). Die Pfeile kennzeichnen dabei die Fließrichtung des Wassers. (2) Entlang einer Kante haben alle Höhen zu- bzw. abnehmende Werte. Für den dargestellten DGM-Ausschnitt (rechts) mit Höhen codiert als Integerzahlen ist diese Annahme zutreffend. Alle Pixelwerte entlang der Kante steigen von der linken unteren zur rechten oberen Ecke an (10 – 13 – 15 – 17 – 22 – 29 – 31 – 36).

in den Daten zu sein, wird eine kleine Abweichung  $\rho$  von diesem Trend zugelassen. Beide Bedingungen sind mittels

$$U_f(X) = \sum_{e_j \in X} p_f \cdot \left( n_{f_1} + \frac{n_{f_2}(e_j, \rho)}{l(e_j)} \right). \quad (4.8)$$

kombiniert. Hierbei entspricht  $n_{f_1}$  der Anzahl der Knoten, die dem ersten Kriterium widersprechen. Für jede Kante  $e_j$  wird zudem die Anzahl der Pixel  $n_{f_2}(e_j)$ , die dem zweiten Kriterium widersprechen, gezählt und über die Länge  $l(e_j)$  der Kante normalisiert. Eine Gewichtung des Terms erfolgt mit dem Faktor  $p_f \in [0, \infty)$ .

### 4.3. Änderungen der Objektkonfiguration

Der *Forest Point Process* ist in ein RJMCMC-Sampling eingebunden. Hier wird in jeder Iteration eine neue Objektkonfiguration in Abhängigkeit der vorherigen Konfiguration bewertet. Die Bewertung der neuen Konfiguration erfolgt über die Green-Ratio (Gleichung 3.11), welche sich unter Berücksichtigung der eingeführten Energiefunktion  $U$  und dem Temperaturparameter  $T_t$  zu

$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{Q_i^r}}{p_{Q_i}} \frac{Q(X, h|X', h')}{Q(X', h'|X, h)} \left| \det\left(\frac{\partial f_{X \rightarrow X'}(X, h)}{\partial(X, h)}\right) \right| \quad (4.9)$$

ergibt. Für das Sampling sind ein Modell für die Übergänge von einer Objektkonfiguration zu einer neuen Konfiguration sowie der dazugehörige Kernel  $Q_i$  zu definieren. Im Folgenden werden drei Arten von Änderungen zugelassen, von denen eine pro Iteration zufällig ausgewählt wird: (1) *Birth-and-Death*: Knoten und Kanten werden dem Wald hinzugefügt bzw. daraus entfernt, (2) *Modifikation*: die Parameter des Waldes werden modifiziert, (3) *Split-and-Merge*: zwei Knoten werden zu einem zusammengeführt oder aus einem Knoten zwei erzeugt. Für jede Änderung ist dabei auch die inverse Änderung  $Q_i^r$  definiert, um die in Abschnitt 3.2.3 geforderte Reversibilität der Markov-Kette zu gewährleisten.

### 4.3.1. Birth-and-Death

Während der Optimierung werden Knoten und Kanten dem Wald hinzugefügt oder aus diesem entfernt. Der Wald wird auf diese Weise iterativ aufgebaut, wobei jedes Hinzufügen (*Birth*) von Knoten und Kanten durch das Entfernen (*Death*) hiervon wieder rückgängig gemacht werden kann. Die dazugehörige Änderung ist mit dem Kernel  $Q_{BD}$  modelliert.

Im Fall der *Birth*-Änderung wird die Position des neuen Knotens  $(x_j, y_j)$  zufällig auf Basis einer *Wahrscheinlichkeitskarte* bestimmt. Diese ordnet jedem Pixel im DGM eine Wahrscheinlichkeit zu, Teil des Netzes zu sein (siehe Abschnitt 4.4.1). Sofern kein Knoten mit denselben Koordinaten vorhanden ist, wird der Knoten dem Graphen hinzugefügt. Da das aufgestellte Modell die Verbindung zu mindestens einem Punkt im Wald erfordert, wird in der lokalen Nachbarschaft  $r$  nach weiteren Punkten gesucht. Für jeden dieser Punkte wird überprüft, ob eine Verbindung Zyklen oder sich schneidende Kanten im Graphen verursacht. Von allen Knoten in der Nachbarschaft, für die dies nicht der Fall ist, wird einer zufällig ausgewählt und mit dem ersten Knoten  $(x_j, y_j)$  durch eine Kante verbunden (siehe Abbildung 4.7). Sofern kein Knoten in der Nachbarschaft existiert, wird die Position eines zweiten Punktes  $(x_{(j+1)}, y_{(j+1)})$  auf Basis der Wahrscheinlichkeitskarte in der lokalen Nachbarschaft generiert und beide Knoten sowie die verbindende Kante – und damit ein neuer Baum – dem Wald hinzugefügt. Anschließend wird eine Breite für die Kante gewählt. Um die unterschiedlichen Breiten von Flüssen im Netz zu berücksichtigen, wird eine Gleichverteilung für alle Werte innerhalb einer minimalen und einer maximalen Breite  $w_{min}$  und  $w_{max}$  angesetzt. Beide Grenzwerte werden für jede Szene gegeben.

Insgesamt werden bei der Änderung *Birth* dem Wald eine Kante und ein oder zwei Knoten hinzugefügt. Das Verhältnis der Kernel in Gleichung 4.9 reduziert sich auf die Wahrscheinlichkeit  $p(n)$  für die Anzahl an Knoten im Wald. Folglich ergibt sich für das Verhältnis der Kernel der *Birth*-Änderung

$$\frac{Q_D(X, h|X', h')}{Q_B(X', h'|X, h)} = \frac{p(n|n')}{p(n'|n)} = \frac{\lambda^{n'} e^{-\lambda}}{n!} \cdot \frac{n!}{\lambda^n e^{-\lambda}} = \begin{cases} \frac{\lambda}{n'}, & n' = n + 1 \\ \frac{\lambda^2}{n' \cdot (n' - 1)}, & n' = n + 2. \end{cases} \quad (4.10)$$

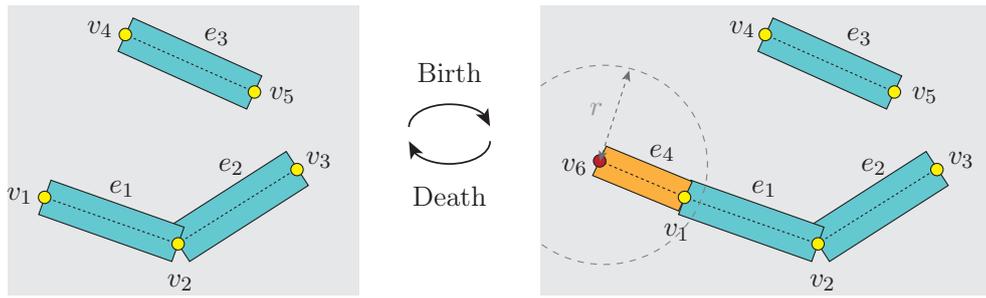
Die mit einem Hochkomma gekennzeichneten Parameter gehören dabei der neuen Konfiguration an.  $n'$  entspricht somit der Anzahl an Knoten in der neuen Konfiguration  $X'$ . Der Parameter  $\lambda$  gibt den Erwartungswert für die Anzahl an Knoten an (siehe Gleichung 3.2), worüber der Bezug des Gibbs-Punktprozesses zum Poisson-Punktprozess hergestellt wird. In die Green-Ratio fließt darüber hinaus die Jakobi-Determinante ein, deren Betrag für die *Birth*-Änderung Eins beträgt (siehe Anhang A). Daher folgt für die Green-Ratio für den Fall  $n' = n + 1$

$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{QD}}{p_{QB}} \frac{\lambda}{n'}, \quad (4.11)$$

bzw. für den Fall  $n' = n + 2$

$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{QD}}{p_{QB}} \frac{\lambda^2}{n' \cdot (n' - 1)}, \quad (4.12)$$

wobei  $p_{QD}$  und  $p_{QB}$  die Wahrscheinlichkeiten für die Wahl von *Birth*- und *Death*-Änderung angeben.



**Abbildung 4.7.:** Im Beispiel setzt sich der initiale Wald aus fünf Knoten  $\{v_1, v_2, v_3, v_4, v_5\}$  und drei Kanten  $\{e_1, e_2, e_3\}$  zusammen. Beim *Birth*-Ereignis werden ein Knoten und eine Kante, hier  $v_6$  und  $e_4$ , dem Wald hinzugefügt. Im Fall des *Death*-Ereignisses werden sie aus dem Wald entfernt.

Im Fall der *Death*-Änderung wird zufällig ein Knoten mit nur einer inzidenten Kante gewählt und der Knoten sowie die Kante aus dem Wald entfernt. Sofern der adjazente Knoten mit keinen weiteren Knoten im Wald verbunden ist, wird er ebenfalls entfernt. Insgesamt werden auf diese Weise eine Kante und ein oder zwei Knoten während der *Death*-Änderung aus dem Graphen gelöscht. Wie bei der *Birth*-Änderung fließen lediglich die Wahrscheinlichkeiten für die Anzahl an Knoten in das Verhältnis der Kernels ein. Die Anzahl ist dabei um ein oder zwei im Vergleich zur vorherigen Konfiguration reduziert. Damit ergibt sich für das Verhältnis der Kernel bei der *Death*-Änderung

$$\frac{Q_B(X, h | X', h')}{Q_D(X', h' | X, h)} = \frac{\lambda^{n'} e^{-\lambda}}{n'!} \cdot \frac{n!}{\lambda^n e^{-\lambda}} = \begin{cases} \frac{n'}{\lambda}, & n' = n - 1 \\ \frac{n' \cdot (n' - 1)}{\lambda^2}, & n' = n - 2. \end{cases} \quad (4.13)$$

Erneut beträgt die Jakobi-Determinante Eins und somit die Green-Ratio im Fall von  $n' = n - 1$

$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{QB}}{p_{QD}} \frac{n'}{\lambda} \quad (4.14)$$

und im Fall von  $n' = n - 2$

$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{QB}}{p_{QD}} \frac{n' \cdot (n' - 1)}{\lambda^2}, \quad (4.15)$$

wobei  $p_{QD}$  und  $p_{QB}$  die Wahrscheinlichkeiten für die Wahl der *Birth*- und *Death*-Änderung angeben.

### 4.3.2. Modifikation

Bei der Modifikation der Parameter des Waldes wird zwischen drei Arten von Änderungen unterschieden:

- (1) der Modifikation der Koordinaten eines Knotens
- (2) der Modifikation der Breite einer Kante
- (3) der Modifikation des Grads eines Knotens.

Alle Modifikationen werden dabei als gleich wahrscheinlich betrachtet und eine von ihnen zufällig ausgewählt. Jeder Typ von Änderung ist in Abbildung 4.8 veranschaulicht. (1) Für die Änderung der Koordinaten wird ein Verschiebungsvektor  $\vec{b}$  innerhalb der lokalen Nachbarschaft erzeugt, wobei alle Positionen in der lokalen Nachbarschaft als gleich wahrscheinlich betrachtet werden. Sofern die Verschiebung zu der neuen Position nicht dazu führt, dass sich Kanten im Objektraum schneiden, und noch kein Knoten an der neuen Position vorliegt, werden die Koordinaten des Knotens geändert. (2) Bei der Änderung der Breite wird für eine zufällig gewählte Kante eine neue Breite generiert. Hierfür werden alle Werte innerhalb eines kleinen Intervalls um die aktuelle Breite herum als gleich wahrscheinlich betrachtet und ein Wert zufällig bestimmt. (3) Ändert sich der Grad eines Knotens, wird ein Knoten im Wald ausgewählt und seine Anzahl an Verbindungen geändert. Dies geschieht durch Modifikation der Adjazenzliste, indem eine Kante zum Wald hinzugefügt oder daraus entfernt wird. Beide Möglichkeiten werden als gleich wahrscheinlich betrachtet und eine davon zufällig gewählt. Sofern sich der Grad des Knotens erhöhen soll, wird innerhalb des Radius  $r$  nach benachbarten Knoten gesucht. Diese müssen die Bedingung erfüllen, dass durch die Kante kein Zyklus im Graph oder ein Schnitt im Objektraum mit einer bereits bestehenden Kante entsteht. Von allen Knoten, die diese Bedingung erfüllen, wird ein Knoten zufällig ausgewählt und eine Kante, welche beide Knoten verbindet, dem Wald hinzugefügt. Da Zyklen im Graph ausgeschlossen sind, werden auf diese Weise zwei Bäume miteinander verbunden. Sofern kein benachbarter Knoten existiert, bleibt die Konfiguration unverändert. Bei der Reduktion des Knotengrads werden zufällig ein Knoten und eine seiner inzidenten Kanten gewählt. Diese Kante wird im Graphen gelöscht, sofern alle weiteren Knoten nach wie vor durch eine weitere Kante mit dem Wald verbunden sind. Andernfalls wird keine Änderung vorgenommen.

Für die Modifikation der Parameter des Waldes beträgt die Green-Ratio

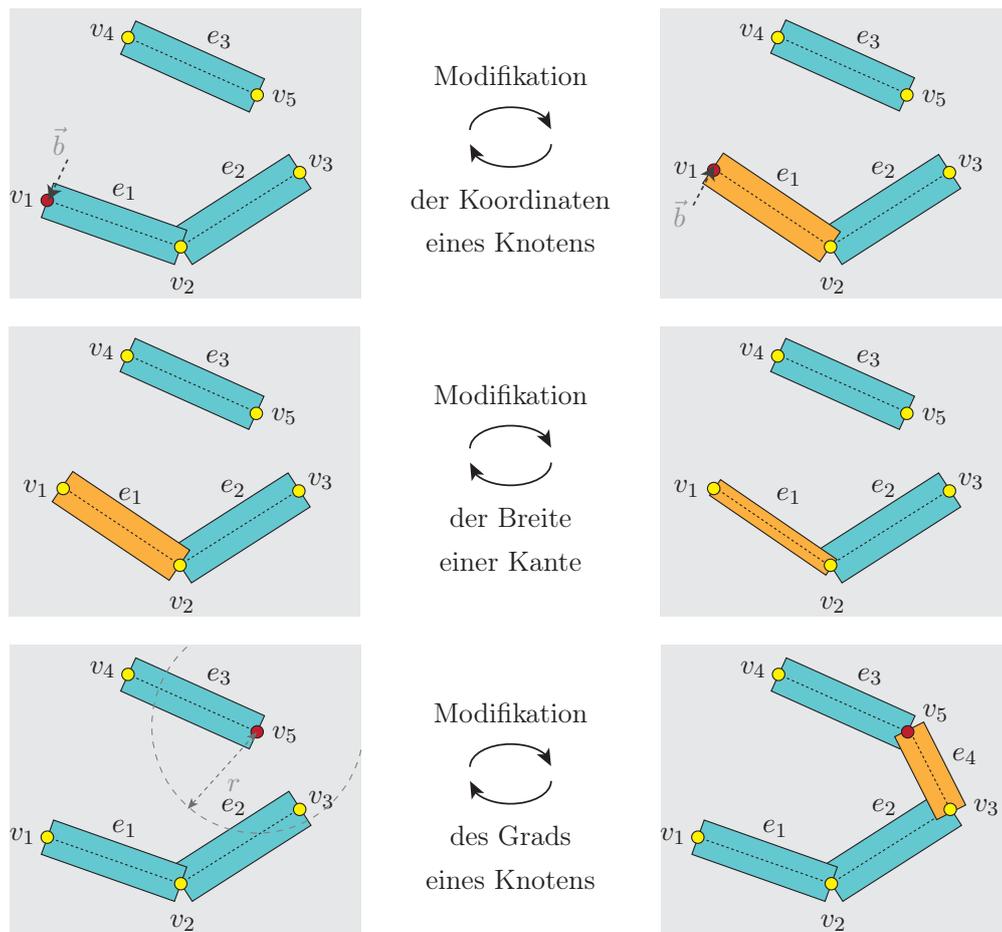
$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{QM_o}^r}{p_{QM_o}}, \quad (4.16)$$

wobei  $p_{QM_o}^r$  und  $p_{QM_o}$  die Wahrscheinlichkeiten sind, den jeweiligen Modifikationskernel und seine reversible Änderung zu wählen. Da die Koordinaten in der Nachbarschaft bzw. die Breiten innerhalb des Änderungsintervalls als gleich wahrscheinlich betrachtet werden, wird der Quotient der Kernel zu Eins. Ebenso beträgt die Jakobi-Determinante Eins.

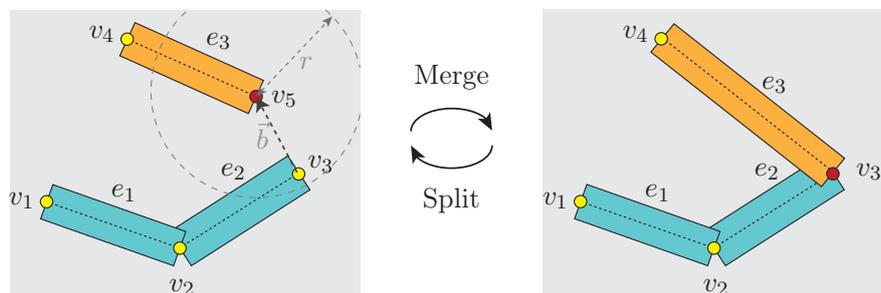
### 4.3.3. Split-and-Merge

Der dritte Typ von Änderung ist ein *Split-and-Merge*-Ereignis, bei dem zwei Knoten zusammengeführt oder getrennt werden.

Im Fall der *Merge*-Änderung wird ein Knoten zufällig im Wald gewählt. Anschließend erfolgt die Suche nach Knoten innerhalb einer lokalen Nachbarschaft  $r$ . Es wird überprüft, ob das Zusammenfügen der jeweiligen Knoten zu einem Zyklus oder zum Schnitt von zwei Kanten führt. Von allen Knoten, für die dies nicht der Fall ist, wird einer zufällig ausgewählt. Dieser Knoten wird für alle benachbarten Punkte des ursprünglichen Knotens als neuer Nachbar in der Adjazenzliste gesetzt. Der ursprüngliche Knoten wird dann aus dem Graphen gelöscht (Abbildung 4.9). Sofern kein geeigneter Knoten in der Nachbarschaft gefunden wird, wird keine Änderung vorgenommen.



**Abbildung 4.8.:** Bei der Modifikation werden die Parameter des Waldes geändert. (1) Die Koordinaten eines Knotens, hier  $v_1$ , werden geändert, indem ein zufälliger Verschiebungsvektor  $\vec{b}$  in der lokalen Nachbarschaft erzeugt wird. Die inverse Modifikation ist durch die Verschiebung in umgekehrter Richtung gegeben. (2) Eine Kante wird zufällig gewählt, hier  $e_1$ , und eine neue Breite hierfür generiert. (3) Der Grad eines Knotens wird geändert, hier für Knoten  $v_5$ , indem eine Kante, hier  $e_4$ , der Konfiguration hinzugefügt bzw. in der inversen Modifikation aus dem Wald entfernt wird.



**Abbildung 4.9.:** Beim *Merge*-Ereignis wird ein Knoten zufällig gewählt, hier  $v_5$ , und mit einem Knoten in der Nachbarschaft  $r$ , hier  $v_3$ , zusammengeführt. Knoten  $v_5$  wird dann aus dem Wald entfernt. Bei der inversen Änderung, dem *Split*-Ereignis, wird für den Knoten  $v_3$  ein Verschiebungsvektor  $\vec{b}$  in der lokalen Nachbarschaft zufällig generiert und der neue Knoten  $v_5$  an dieser Position eingefügt.

Die Determinante der Jakobi-Matrix für die *Merge*-Änderung beträgt Eins. Folglich ergibt sich für die Green-Ratio

$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{QS}}{p_{QM}} \frac{n'}{\lambda}, \quad (4.17)$$

was analog zu der Green-Ratio des *Death*-Ereignisses (Gleichung 4.14) hergeleitet werden kann, bei dem ebenfalls ein Knoten aus dem Graph entfernt wird.

Im umgekehrten Fall, dem *Split*-Ereignis, wird ein Knoten mit mindestens zwei abgehenden Kanten ausgewählt. Ein Verschiebungsvektor  $\vec{b}$  wird zufällig generiert und ein neuer Knoten an dieser Position eingeführt. Für eine der inzidenten Kanten – welche zufällig gewählt wird – wird diese Position als Endpunkt der Kante in die Adjazenzliste eingetragen. Voraussetzung ist, dass hierbei kein Schnitt von Kanten erzeugt wird und zuvor noch kein Knoten an der neuen Position im Graph vorhanden war.

Die Green-Ratio für das *Split*-Ereignis ergibt sich analog zu dem *Birth*-Ereignis (Gleichung 4.11) mit

$$R = \exp\left(-\frac{U(X') - U(X)}{T_t}\right) \frac{p_{QM}}{p_{QS}} \frac{\lambda}{n'}, \quad (4.18)$$

wobei  $p_{QM}$  und  $p_{QS}$  die Wahrscheinlichkeiten für die Wahl der Ereignisse *Merge* und *Split* sind.

## 4.4. Erweiterungen

Ein Ziel des entwickelten Ansatzes ist es, dass die Zielverteilung möglichst schnell gegen das Energieoptimum konvergiert. Aus diesem Grund werden zwei Erweiterungen im vorgestellten Ansatz integriert. Zum einen wird durch die Einführung einer *Wahrscheinlichkeitskarte* den Pixeln in den Rasterdaten eine Wahrscheinlichkeit zugeordnet, zum Liniennetz zu gehören. Neue Punkte werden dann bevorzugt an Orten mit hoher Wahrscheinlichkeit eingefügt. Zum anderen ist ein hierarchisches Vorgehen implementiert. Hierbei liegen die Eingangsdaten in unterschiedlichen Auflösungsstufen vor. Die Extraktion des Liniennetzes wird dann für breite Linien in einer niedrigen Auflösungsstufe durchgeführt, während die feinen Strukturen erst in höheren Auflösungsstufen detektiert werden. Auf diese Weise kann der Suchraum während der Optimierung ebenfalls eingeschränkt werden.

### 4.4.1. Wahrscheinlichkeitskarte

Die Integration von A-priori-Wissen in den markierten Punktprozess wurde in der Literatur in verschiedenen Ansätzen behandelt. Als Vorreiter sind Tu & Zhu [2002] mit ihren Arbeiten anzuführen, die Wahrscheinlichkeiten für das Vorkommen von Objekten aus dem Ergebnis von vorgeschalteten Bildoperatoren ableiten. In den Arbeiten von Benedek & Martorella [2014]; Utasi & Benedek [2011] und Ge & Collins [2009] wird dem Samplingansatz eine Vordergrund-Hintergrund-Klassifikation vorgeschaltet und der Punktprozess anschließend nur auf den Vordergrundpixeln ausgeführt. Eine Karte, die jedem Pixel die Wahrscheinlichkeit für das Vorkommen eines Objektes in optischen Bilddaten bzw. Intensitätsdaten mobiler Laserscannersysteme zuordnet, wird bei Benedek et al. [2012] und Hervieu et al. [2015] verwendet. Hierfür werden verschiedene Merkmale wie die Homogenität der Grauwerte und lokale Gradientenorientierungen bzw. die Intensitäten der Laserscannerdaten berücksichtigt.

Die Idee einer Wahrscheinlichkeitskarte wird im Folgenden aufgegriffen. Hierfür werden Merkmale aus dem DGM abgeleitet und ein einfacher Schwellwertansatz genutzt. Für die Flussdetektion in nahezu horizontalem Gelände wie dem Wattenmeer erweist sich in der Regel bereits ein Schwellwert  $\tau_z$  für die Höhe  $z$  als geeignet. Alle Pixel mit Höhen unterhalb dieses Wertes werden dann mit einer hohen Wahrscheinlichkeit  $p(x, y)$  ausgegeben, zum Netz zu gehören:

$$p(x, y) = \begin{cases} p_1 & \text{falls } z < \tau_z \\ p_2 & \text{sonst,} \end{cases} \quad (4.19)$$

wobei  $p_1 > p_2$ . In Geländeformen mit größeren Höhenunterschieden ist eine solche Annahme nicht zutreffend. Stattdessen werden hier Krümmungen im Gelände berücksichtigt, welche in den Bereichen der Flüsse hoch sind. Die Krümmungen  $\kappa$  werden basierend auf den zweiten Ableitungen in senkrechter Richtung zu den Gradienten im DGM mit

$$\kappa = \frac{\frac{\partial^2 g(x,y)}{\partial x^2} \frac{\partial g(x,y)}{\partial y} + \frac{\partial^2 g(x,y)}{\partial y^2} \frac{\partial g(x,y)}{\partial x} - 2 \frac{\partial^2 g(x,y)}{\partial y \partial x} \frac{\partial g(x,y)}{\partial x} \frac{\partial g(x,y)}{\partial y}}{\frac{\partial g(x,y)}{\partial x} + \frac{\partial g(x,y)}{\partial y}} \quad (4.20)$$

bestimmt und mit einem Gauß-Filter zusätzlich geglättet. Erneut wird ein Schwellwert  $\tau_\kappa$  berücksichtigt und alle Pixel oberhalb dieses Wertes mit einer hohen Wahrscheinlichkeit belegt:

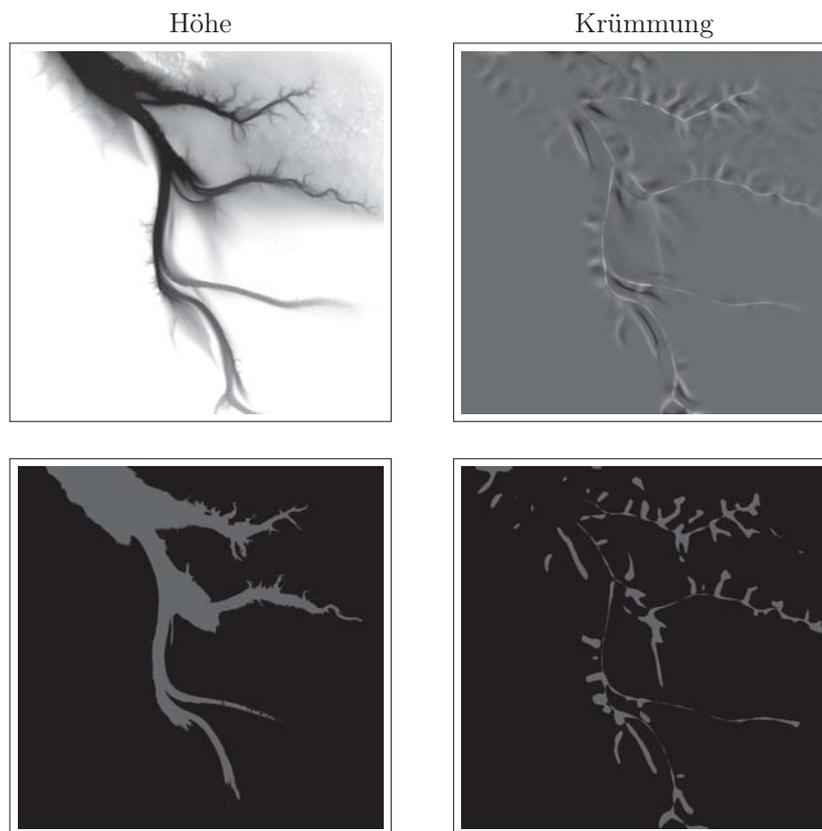
$$p(x, y) = \begin{cases} p_1 & \text{falls } \kappa > \tau_\kappa \\ p_2 & \text{sonst,} \end{cases} \quad (4.21)$$

wobei  $p_1 > p_2$ . Dem Modell liegt die Annahme zugrunde, dass Flüsse einen konvexen Querschnitt aufweisen, während konkave Verläufe ausgeschlossen werden können. Ein Beispiel für beide Arten von Wahrscheinlichkeitskarten ist in Abbildung 4.10 gegeben.

#### 4.4.2. Hierarchische Extraktion

Für die hierarchische Extraktion mittels markierter Punktprozesse findet sich ein Beispiel bei Lacoste et al. [2006]. Hierbei werden medizinische Daten von Arterien in zwei Auflösungsstufen betrachtet. In der geringeren Auflösungsstufe werden zunächst breite Arterien detektiert, die als Liniensegmente modelliert sind. In einem Zwischenschritt werden diese zu Polylinien zusammengeführt und die Breite der Liniensegmente durch Kantenextraktion in den Daten höherer Auflösung optimiert. Ausgehend von diesem Ergebnis wird in einem zweiten Punktprozess das Netz aus Arterien in Daten höherer Auflösung verdichtet. Hierfür werden unter anderem Änderungsoperationen definiert, die das Einfügen oder Entfernen von Liniensegmenten an den Enden der Polylinien ermöglichen. Zudem ist es möglich, ganze Polylinien zu entfernen oder der bestehenden Konfiguration hinzuzufügen.

Im Folgenden wird die Idee der hierarchischen Extraktion für große Szenen aufgegriffen. Hierbei werden zwei oder mehr Auflösungsstufen für die Eingangsdaten erzeugt. Die hierarchische Extraktion wird dann wie folgt durchgeführt. Zunächst erfolgt die Suche nach großen Flüssen bzw. breiten Linien in den Eingangsdaten der geringsten Auflösung. Für deren Detektion sind geeignete Parameterein-



**Abbildung 4.10.:** Für die Wahrscheinlichkeitskarte werden die Höhen im DGM (oben links) oder die Geländekrümmung (oben rechts) berücksichtigt, hier am Beispiel für ein Prielnetz aufgezeigt. In einem schwellwertbasierten Ansatz werden Pixeln mit einem geringen Höhenwert bzw. mit einem hohen Krümmungswert eine hohe Wahrscheinlichkeit zugeordnet, zum Netz zu gehören. Die Wahrscheinlichkeitskarten (unten) sind in diesen Bereichen hoch (hell), in den übrigen Bereichen gering (dunkel).

stellungen gewählt. Die resultierende Graphkonfiguration wird anschließend als fest angenommen und nicht mehr verändert. Um in einer späteren Hierarchiestufe nicht an den bereits als Netz detektierten Orten erneut nach Liniensegmenten zu suchen, wird in der Wahrscheinlichkeitskarte für alle Pixel unterhalb der Segmentflächen die Wahrscheinlichkeit auf einen geringen Wert gesetzt. Nach und nach werden dann feinere Strukturen im Liniennetz in Daten höherer Auflösung gesucht.

## 4.5. Konzeptioneller Ablauf

Die angeführten Modelle und Erweiterungen werden für die Umsetzung des *Forest Point Process* wie folgt zusammengesetzt und die Extraktion des Liniennetzes dabei iterativ durchgeführt:

1. Vorverarbeitung: Erzeuge für die Eingangsdaten unterschiedliche Auflösungsstufen, sofern eine hierarchische Suche vorgenommen werden soll. Berechne für jede Auflösungsstufe eine Wahrscheinlichkeitskarte für das Vorkommen des Liniennetzes.
2. Wenn bereits ein Ergebnis aus einer vorherigen Hierarchiestufe vorliegt, lies dieses ein. Initialisiere  $T$ .

3. Wähle zufällig eine der Änderungen aus:

- Birth-and-Death
- Modifikation
- Split-and-Merge

und generiere alle dafür erforderlichen Parameter auf Basis der vorgegebenen Wahrscheinlichkeiten. Wenn die Änderung nicht möglich ist – z.B. kann die Aktion *Death* nicht durchgeführt werden, sofern der Graph leer ist – wähle eine neue Änderung.

4. Erzeuge entsprechend der gewählten Änderung eine neue Objektkonfiguration  $X'$ . Bestimme die Energiedifferenz  $\Delta U = U(X') - U(X)$  durch Berechnung der Differenz der Daten- und Priorenergie aller Knoten und Kanten, die von der Änderung betroffen sind.
5. Bestimme die Green-Ratio  $R$  entsprechend Gleichung 4.9 sowie die Akzeptanzwahrscheinlichkeit für diese Objektkonfiguration über  $\alpha = \min(1, R)$ .
6. Generiere eine gleichverteilte Zufallszahl  $\gamma$ . Ist  $\gamma < \alpha$ , nimm die neue Konfiguration  $X'$  an. Andernfalls lehne sie ab und behalte die alte Objektkonfiguration bei.
7. Verringere  $T$  und wiederhole die Schritte 3. – 6. solange, bis eine vorgegebene Anzahl von Iterationen erreicht ist.

Als Ergebnis des *Forest Point Process* liegt der Graph vor, der das Liniennetz bei den gegebenen Daten und unter Berücksichtigung des Modellwissens am besten beschreibt.

## 4.6. Diskussion

Das vorgestellte Verfahren ist für die Extraktion von Liniennetzen in Rasterdaten konzipiert. Als Objektmodell wird hierbei ein Graph in Form eines Waldes gewählt. Im Gegensatz zu anderen Verfahren in der Literatur, die ein Liniennetz aus einzelnen Segmenten zusammensetzen, ist die Nachbarschaft zwischen Punkten eindeutig durch den Graph gegeben und muss nicht unter Berücksichtigung von Distanz- und Winkelkriterien definiert werden. Die Methodik des *Forest Point Process* kann mit Hilfe verschiedener Parameter für unterschiedliche Szenen und Anwendungen angepasst werden. Strategien über die Wahl geeigneter Größen hierfür sind im Zusammenhang mit dem Aufbau der Experimente in Abschnitt 5.3 sowie in den Ergebnissen in Abschnitt 6.2.2 diskutiert.

**Beschränkungen:** Das Objektmodell des *Forest Point Process* ist auf zyklensfreie Graphen beschränkt. Dies erscheint für die Anwendung im Bereich der Gewässerdetektion als sinnvoll, da das Wasser stets bergab fließt und sich kleinere Gewässerläufe zu einem größeren Gewässerlauf verbinden. Bei Flüssen und Prieln besteht jedoch die Möglichkeit, dass das Wasser um eine Insel oder Sandbank herum fließt und wieder zusammenläuft. Dies lässt sich mit dem entwickelten Modell nicht beschreiben.

Im Modell des Priorterms der Energiefunktion werden jene Graphkonfigurationen als geeignet angesehen, in denen der Graph verbunden ist. Konfigurationen, die sich aus mehr als einem Baum zusammensetzen, werden daher bestraft. Als kritisch kann dieser Term betrachtet werden, sofern

die Verbindungen des Liniennetzes außerhalb der Szene liegen. Zudem ist hierbei nicht berücksichtigt, dass sich der Graph bedingt durch die iterative Konstruktion des Liniennetzes in den anfänglichen Iterationen ohnehin aus mehreren Teilen zusammensetzt. Hier ist zu untersuchen, inwiefern das gesuchte Liniennetz durch die Energieminimierung in den anderen Termen der Energiefunktion dennoch extrahiert werden kann.

**Übertragbarkeit:** Obwohl das Modell des Datenterms für die Extraktion von Flussnetzen in einem DGM entwickelt wurde, lässt es sich grundsätzlich auf andere Arten von Netzen in Bildern, wie z.B. Straßen- und Gefäßnetze, übertragen. Anstelle von Höhen werden dann Grauwerte in den Rasterdaten ausgewertet. Im Samplingverfahren ergeben sich dabei die besten Objektkonfigurationen, sofern hohe Grauwertgradienten an den Rändern der Segmente vorliegen und die Grauwerte im Querprofil homogen sind. Ist das Liniennetz in den Eingangsdaten dunkler als die Umgebung – und die Gradientenbeträge an den Rändern entlang des Normalenvektors positiv – kann das aufgestellte Modell direkt verwendet werden. Andernfalls ist das Vorzeichen im Datenterm der Gradienten  $U_g$  umzudrehen bzw. ist das komplementäre Bild der Eingangsdaten zu verwenden. Der Priorterm bezüglich der Fließrichtung  $U_f$  ist bezüglich des zweiten Kriteriums, welches Höhengsprünge entlang einer Kante bestraft, relevant. Für Liniennetze mit homogenen Grauwertverteilungen in Bildern kann es genutzt werden, um starke Variationen der Grauwerte entlang der Liniensegmente auszuschließen.

## 5. Aufbau der Experimente

Das entwickelte Verfahren wird anhand von unterschiedlichen Datensätzen und für verschiedene Anwendungsgebiete, wie die Extraktion von Gewässer- und Gefäßnetzen, evaluiert. In diesem Kapitel wird zunächst der Aufbau der Experimente und die damit verbundene Zielsetzung angeführt (Abschnitt 5.1). Anschließend werden die dabei verwendeten Datensätze (Abschnitt 5.2) sowie die für die Experimente gewählten Parametereinstellungen (Abschnitt 5.3) vorgestellt. Darüber hinaus wird auf die Evaluationsmethoden eingegangen, die genutzt werden, um die Ergebnisse quantitativ auszuwerten (Abschnitt 5.4).

### 5.1. Zielsetzung

Die Zielsetzung dieser Arbeit ist die Objektextraktion von Liniennetzen in Rasterdaten. Als Ergebnis des *Forest Point Process* liegt ein Wald bestehend aus Knoten und Kanten vor. Wie gut dieser das Liniennetz beschreibt, kann anhand von Referenzdaten bewertet werden. Hierfür werden die Ergebnisse quantitativ auf Grundlage der in Abschnitt 5.4 vorgestellten Evaluationsmethoden ausgewertet. Darüber hinaus wird in den aufgezeigten Experimenten folgenden Fragestellungen nachgegangen:

*(1) Wie wirkt sich die Abkühlung des Simulated Annealing auf die Ergebnisse aus? Welchen Anteil haben die einzelnen Terme der Energiefunktion auf die Qualitätsmaße der Ergebnisse? Inwiefern können die Experimente trotz Generierung von Zufallszahlen wiederholt werden?*

Um zu überprüfen, ob und wie gut sich das gewählte Modell für die Extraktion von Liniennetzen eignet, werden einzelne Teile des Modells näher untersucht. Hierzu zählt das gewählte Abkühlungsverfahren im Simulated Annealing. Darüber hinaus ist die Analyse des Nutzens der einzelnen Energiet Terme auf die Qualitätsmaße der Ergebnisse Bestandteil der Experimente. Den Einfluss, den die Ziehung von Zufallszahlen im Sampling auf die Ergebnisse nimmt, wird durch mehrmalige Wiederholung der Experimente überprüft.

*(2) Wie gut eignet sich das Verfahren für Gewässernetze in unterschiedlichen Geländeformen? Wie schneidet das Verfahren im Vergleich zu Standardverfahren für diese Aufgabenstellung ab? Welchen Einfluss haben die gewählten Parametereinstellungen auf das Ergebnis, insbesondere physikalische Parameter? Wie lassen sich Zeitreihen als Eingangsdaten mit dem Verfahren auswerten?*

Der *Forest Point Process* wird für Szenen mit gänzlich unterschiedlichen Geländeverläufen angewendet. Hieran wird überprüft, inwiefern sich das Verfahren für die Extraktion von Gewässernetzen in verschiedenen Szenen eignet. Die Ergebnisse werden zudem dem Resultat eines Standardverfahrens zur Extraktion von Gewässernetzen [Holmgren, 1994] gegenübergestellt. Da das Modell des *Forest*

*Point Process* mit Hilfe verschiedener Parameter vom Nutzer an individuelle Szenen und Aufgabenstellungen angepasst werden kann, wird darüber hinaus untersucht, welchen Einfluss das Variieren dieser Größen auf die Ergebnisse hat. Hierbei ist insbesondere von Interesse, wie sich das Einbinden von physikalischem Wissen im Modell auswirkt. In den Experimenten werden die Parameter zunächst auf geeignete Größen gesetzt, die empirisch bestimmt wurden. Anschließend werden die Parameter nach und nach variiert. Des Weiteren wird eine Möglichkeit aufgezeigt, wie der *Forest Point Process* für Zeitreihen eingesetzt werden kann.

(3) *Welches Potential weist der Ansatz für die Extraktion anderer Arten von Liniennetzen in Bildern auf? Wie schneidet das Verfahren im Vergleich zu anderen Methoden für diese Aufgabenstellung ab?*

Auch wenn der Ansatz für die Extraktion von Gewässernetzen in DGMs konzipiert wurde, können mit dem gewählten Modell andere Arten von Liniennetzen beschrieben werden. Inwiefern das Verfahren auf Bilddaten mit unterschiedlichen Typen von Liniennetzen übertragbar ist, wird anhand verschiedener Bilder überprüft. Für die gewählten Szenen liegen die Ergebnisse anderer Verfahren zur Liniensextraktion aus der Literatur vor. Die Ergebnisse werden quantitativ miteinander verglichen.

## 5.2. Daten

Das Verfahren wird anhand verschiedener Datensätze und im Hinblick auf unterschiedliche Applikationen evaluiert.

Zunächst erfolgt die Extraktion von Priel- und Flussnetzwerken in DGMs. Hierfür werden drei verschiedene Datensätze genutzt, deren charakteristische Parameter in Tabelle 5.1 aufgelistet sind. So wurden synthetische Daten erzeugt, die einen kleinen Ausschnitt eines idealisierten Gewässernetzes simulieren. In diesem Datensatz weisen die Höhen innerhalb des Netzes ein kontinuierliches Gefälle von der Quelle zu der Mündung hin auf. Die Übertragbarkeit des Verfahrens auf echte Daten wird anhand von zwei Testgebieten aufgezeigt, welche sich hinsichtlich ihres Geländeverlaufs signifikant unterscheiden. Zum einen wird ein Testgebiet des niedersächsischen Wattenmeeres im Bereich der Insel Norderney ausgewählt, welches sich über eine Fläche von  $8 \times 3.5 \text{ km}^2$  erstreckt und eine Vielzahl von Prielen beinhaltet. Einige Experimente werden nur für Teilbereiche, *Gebiet 1* und *Gebiet 2*, durchgeführt (siehe Abbildung 5.1). Für *Gebiet 2* liegen DGMs zu drei unterschiedlichen Aufnahmezeitpunkten vor. Die DGMs aller Gebiete stammen aus Laserscannerdaten und sind im Rahmen von Küstenschutzvermessungen im Auftrag des Niedersächsischen Landesbetriebs für Wasserwirtschaft, Küsten- und Naturschutz (NLWKN) oder innerhalb des Forschungsprojektes *WIMO* [Winter et al., 2014] aufgenommen worden. Hierbei wurden die in Tabelle 5.2 aufgeführten Sensoren genutzt. Die Befliegungen der Wattgebiete erfolgte jeweils bei Niedrigwasser. Breite Priele sind auch dann noch mit Wasser bedeckt. Die kleineren Priele fallen zum Teil trocken, was mangels zeitgleich erhobener Luftbilder jedoch nicht nachgewiesen werden kann. Im DGM wird daher unter Umständen die Gewässeroberfläche anstelle des Geländes beschrieben, was auf die Extraktion des Prielnetz jedoch keine signifikanten Auswirkungen hat. Von Seiten des Datenlieferanten ist jeweils ein digitales Geländemodell mit 1 m Rasterweite zur Verfügung gestellt worden. Aus diesen Daten werden im Rahmen einer Vorverarbeitung für einige Untersuchungen DGMs mit geringeren Auflösungsstufen von 2 m, 5 m, 10 m und

**Tabelle 5.1.:** Für die Extraktion von Gewässernetzen werden verschiedene Testgebiete untersucht.  $\Delta z$  gibt hierbei die Differenz zwischen höchstem und niedrigstem Punkt in der Szene an.

Datensatz (DGM)	Größe der Szene [ $m^2$ ]	Rasterweite DGM [ $m$ ]	$\Delta z$ [ $m$ ]
Synthetische Daten	170 x 170	1	1.7
Watt	8000 x 3500	2, 5, 10, 20	10.0
Watt (Gebiet 1)	1001 x 1001	1, 2	1.7
Watt (Gebiet 2)	371 x 541	1	1.1
Vorarlberg	10000 x 7500	5, 10	700
Vorarlberg (Ausschnitt)	2500 x 2500	5, 10	250

**Tabelle 5.2.:** Laserscannersensoren, die für die Erstellung der Daten genutzt wurden.

Sensor	Watt	Gebiet 1	Gebiet 2	Vorarlberg	Ausschnitt
Riegl LMS-VQ 820G	x	-	x (2014)	-	-
Riegl LMS-Q 680i	-	x	x (2012)	-	-
Trimble Harrier 56	-	-	x (2010)	-	-
Optech ALTM 2050	-	-	-	x	x

20  $m$  generiert. Insgesamt ist das Testgebiet im Wattenmeer durch sehr geringe Höhenunterschiede gekennzeichnet. Im DGM der gesamten Szene treten dabei Höhendifferenzen von  $\Delta z = 10 m$  auf, wobei hier auch die Festlandflächen im südöstlichen Bereich des Gebietes berücksichtigt sind. Werden nur die Wattflächen betrachtet, wie z.B. im *Gebiet 1*, liegt die Differenz lediglich bei  $\Delta z = 1.7 m$ .

Eine gänzlich andere Charakteristik weist das zweite gewählte Testgebiet auf, das Gebiet *Vorarlberg*, welches sich im selbigen Bundesland in Österreich befindet. Das digitale Geländemodell wurde hierbei aus Daten luftgestützter Laserscanner des Sensors *Optech ALTM 2050* abgeleitet. Die unregelmäßige Punktwolke mit durchschnittlicher Punktdichte von 1.6 Punkten/ $m^2$  wurde mit Hilfe einer hierarchischen robusten Filterung [Kraus & Pfeifer, 1998] interpoliert und von Seiten des Landesamts für Vermessung und Geoinformation aus Vorarlberg mit einer Gitterweite von 0.5  $m$  zur Verfügung gestellt. Um den Suchraum beim Sampling zu verkleinern, werden aus den Daten DGMs geringerer Auflösungsstufe von 5  $m$  und 10  $m$  generiert und im Rahmen einer hierarchischen Extraktion untersucht. Eine Auflösung der Eingangsdaten von 5  $m$  findet sich ebenfalls für die Gewässernetzextraktion derselben Szene in dem Ansatz von Vetter & Mandlbürger [2014] vor. Das für die Untersuchungen betrachtete Gebiet mit einer Fläche von  $10 \times 7.5 km^2$  umfasst ein stark verzweigtes Flussnetz mit einer Länge von 247.3  $km$  (Abbildung 5.2). Der größte Fluss der Szene ist die Bregenzer Ach, welche außerhalb der Szene in den Bodensee fließt. Ein Teil des Bodensees ist am linken oberen Rand der Szene zu sehen. Zahlreiche kleinere Flüsse münden in den Bodensee bzw. fließen in die Bregenzer Ach. Das Flussnetz durchläuft dabei ein sehr bergiges Gelände. Der Unterschied zwischen niedrigstem und höchstem Punkt innerhalb der Szene liegt bei  $\Delta z = 700 m$ . Einige Untersuchungen werden an der gesamten Szene, andere nur an dem als *Ausschnitt* bezeichneten Testgebiet durchgeführt.

Für die Szene aus *Vorarlberg* sind Luftbilder gegeben, die eine visuelle Auswertung der Ergebnisse zulassen. Für die Wattgebiete liegen ebenfalls Luftbilder vor, welche für eine graphische Darstellung herangezogen werden. Besonders deutlich sind die Strukturen der Priele in den Farbinfrarot (CIR)-Bildern zu erkennen. Anzumerken ist hierbei, dass die Luftbilder und die Laserscannerdaten, die für

die Erstellung des DGM genutzt sind, nicht zeitgleich erhoben wurden. Unterschiede in den Prielnetzen im Luftbild und in den Laserscannerdaten können daher auftreten.

Die Evaluation der Ergebnisse erfolgt anhand von Referenzdaten für die Priel- und Flussnetze. Für die Wattgebiete wurden Referenzdaten manuell erstellt. Hierfür wurden die Umrisse des Netzes in den Eingangsdaten markiert und aus dem Ergebnis ein Binärbild mit den Klassen *Prielnetz* und *Hintergrund* abgeleitet. Mit Hilfe des Skelettierungsansatzes von Strzodka & Telea [2004] wird die Mittelachse des Liniennetzes für die Pixel der Klasse *Prielnetz* bestimmt und als Referenzlinie des Netzes definiert. An den äußeren Enden des Netzes, an denen Standardskelettierungsansätze keine Ergebnisse liefern, wird die Mittelachse manuell digitalisiert. Im Fall der Daten von Österreich liegt ein Referenzflussnetz des Vorarlberger Landesamts für Vermessung und Geoinformation vor, welches die Mittelachsen der Flüsse beinhaltet. Hiervon werden alle sichtbaren Teile des Gewässernetzes als Referenz genutzt. Flussabschnitte, die zum Teil über mehrere hundert Meter hinweg unterirdisch in Rohren verlaufen, werden hingegen nicht betrachtet.

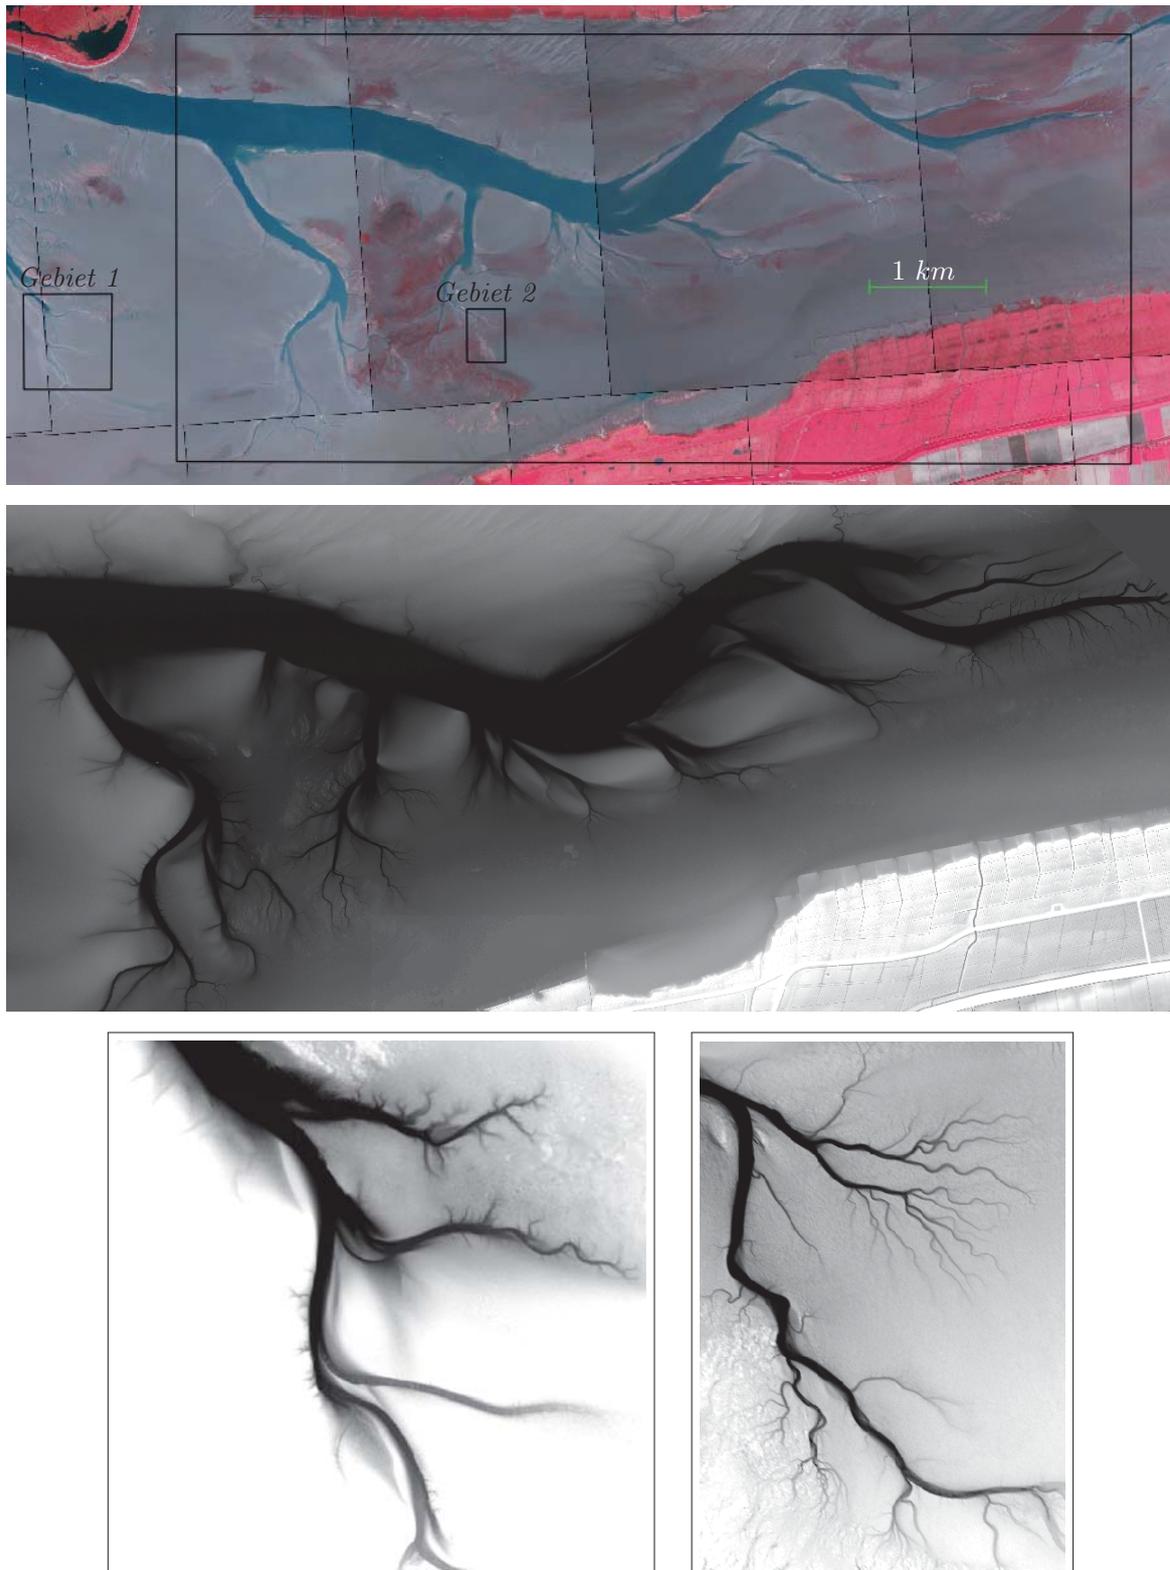
Neben der Extraktion von Gewässernetzen in DGMs wird die Eignung des *Forest Point Process* für Liniennetze unterschiedlicher Art in Bildern untersucht (siehe Abbildung 5.3). Es handelt sich um vier Szenen, die im Folgenden als *Fluss*, *Blatt*, *Retina* und *Kacheln* bezeichnet werden. Ein SPOT-Satellitenbild mit einer geometrischen Auflösung von 10 m ist in der ersten Szene gegeben. Hierin ist ein Flussnetz enthalten. Die Szene *Blatt* zeigt das Blatt eines Laubbaums mit den darin vorliegenden Blattadern. Ein Adernetz innerhalb des Auges ist in der Szene *Retina* dargestellt. Die letzte Szene zeigt eine Vielzahl von Kacheln auf, an dessen Rändern durch die Fugen ein Netz aufgespannt wird. Die Größe der Bilder ist in Tabelle 5.3 aufgelistet. Für alle Datensätze liegen zudem Referenzdaten in Form von Binärbildern vor. Hierin gehören alle Pixel innerhalb des Liniennetzes einer Klasse an. Im Gegensatz zu den Gewässernetzen, bei denen Referenzen für die Mittelachsen bestimmt wurden, werden hierbei die Flächen des Liniennetzes ausgewertet.

**Tabelle 5.3.:** Die Übertragbarkeit des *Forest Point Process* auf Bilder und weitere Arten von Liniennetzen wird anhand verschiedener Bilder aus dem Datensatz von [Verdié & Lafarge, 2014] überprüft.

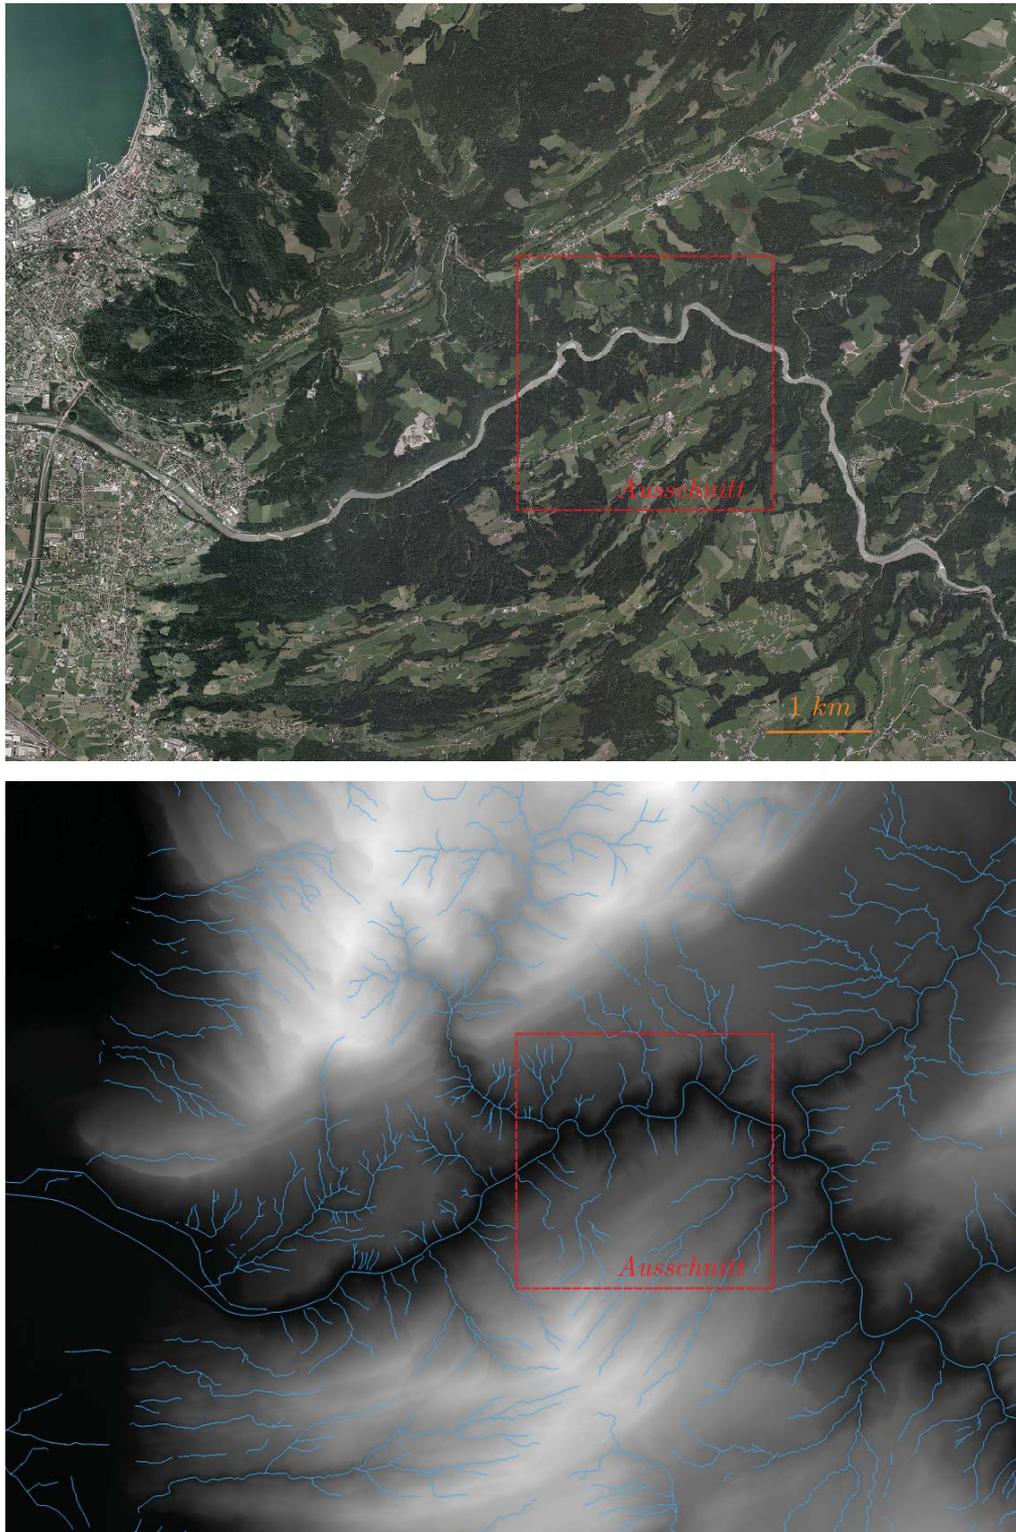
Datensatz (Bilder)	Größe der Szene [px]
Fluss	364 x 320
Blatt	651 x 364
Retina	365 x 378
Kacheln	672 x 523

### 5.3. Parametereinstellungen

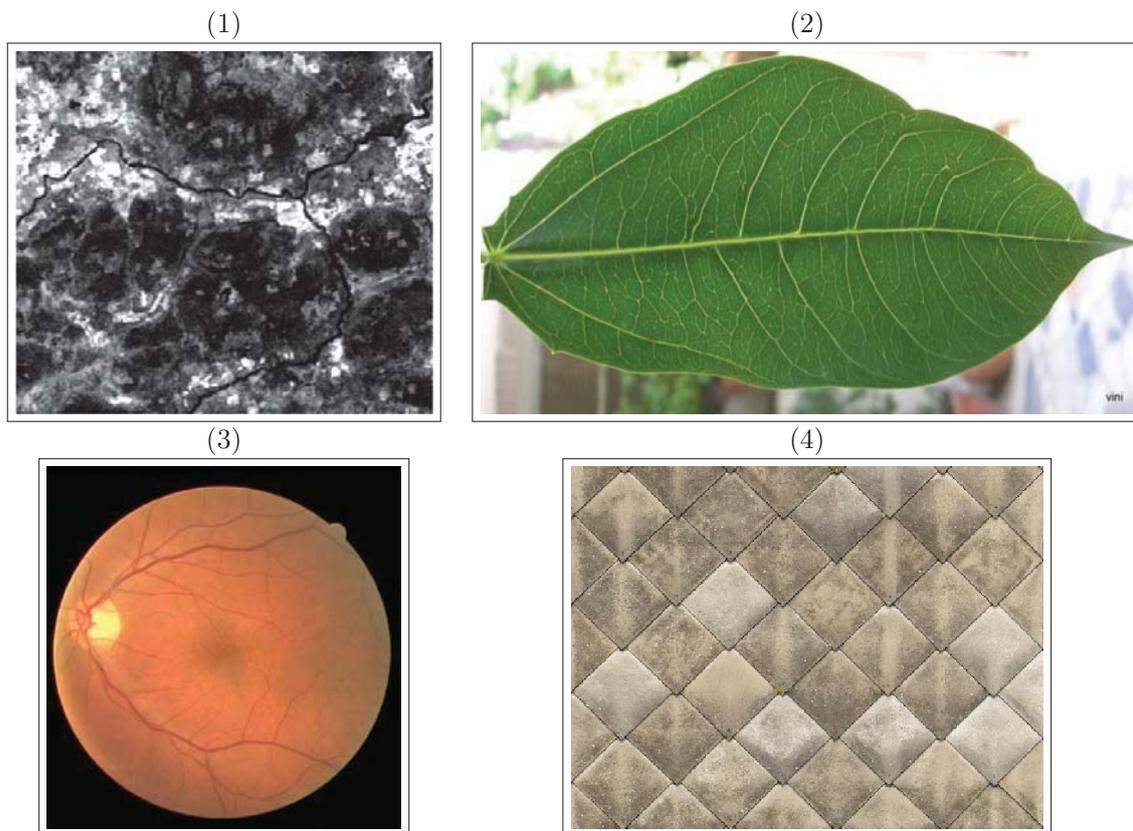
In den Experimenten werden die Parameter auf Werte gesetzt, welche empirisch in vorherigen Untersuchungen ermittelt wurden [Schmidt et al., 2016]. Sofern nicht anders aufgeführt, werden diese Parameter während der Experimente konstant gehalten. Im Allgemeinen können Unterschiede bei den Parametereinstellungen damit erklärt werden, dass die Liniennetze in ihrer Ausprägung variieren. Der Einfluss der Parametereinstellung auf die Ergebnisse wird in Abschnitt 6.2.2 umfangreich untersucht.



**Abbildung 5.1.:** Die Szene *Wattenmeer* erstreckt sich über ein Gebiet von  $8 \times 3.5 \text{ km}^2$ . Im CIR-Luftbild sind die verwendeten Testgebiete gekennzeichnet (oben). Für den großen, schwarz umrandeten Bereich (Mitte) sowie für *Gebiet 1* (unten links) und *Gebiet 2* (unten rechts) ist zudem das DGM dargestellt.



**Abbildung 5.2.:** Die Szene *Vorarlberg* erstreckt sich über ein Gebiet von  $10 \times 7.5 \text{ km}^2$ . Das Luftbild (oben) wird nur zur visuellen Auswertung herangezogen. Die Extraktion des Flussnetzes erfolgt auf Grundlage des DGM (unten). In blau ist das Referenzflussnetz für das Gebiet gegeben. Das rote Quadrat gibt den Ausschnitt an, welcher für einige der Experimente als Eingangsdaten gewählt ist.



**Abbildung 5.3.:** Das Verfahren wird auch anhand unterschiedlicher Liniennetze in Bildern evaluiert. Es handelt sich hierbei um die Szenen (1) *Fluss*, (2) *Blatt*, (3) *Retina* und (4) *Kacheln*.

Die Wahrscheinlichkeiten für die Auswahl der Kernel werden in allen Fällen gleichgesetzt. Die Wahrscheinlichkeit, den *Birth-and-Death*-Kernel zu wählen, ist somit genauso groß wie die Wahrscheinlichkeit, eine Modifikation oder ein *Split-and-Merge*-Ereignis durchzuführen. Innerhalb eines Kerns wird die Wahrscheinlichkeit für eine Änderung und deren inverse Änderung ebenfalls als gleich betrachtet. Daher betragen  $p_{QB} = p_{QD} = p_{QM_o} = p_{QS} = p_{QM} = 0.5$  (Gleichungen 4.11, 4.12, 4.14, 4.15, 4.16, 4.17 und 4.18), die Quotienten der Kernel ergeben somit Eins. Bei der Berechnung des Datenterms  $U_h$  bezüglich der Homogenität der Höhen entlang der Ränder der Segmente im Querprofil wird  $\Delta x$  auf 5 % der Gesamtlänge des Randes gesetzt (siehe Abschnitt 4.2.1). Für den Priorterm bezüglich der Fließrichtung wird eine Abweichung von  $\rho = 0.3 m$  vom geforderten Trend im Höhenverlauf entlang der Mittelachsen zugelassen (Gleichung 4.8). Letzterer Wert kann damit begründet werden, dass die Einzelpunktgenauigkeit der Höhenkomponente beim Laserscanning unterhalb dieses Wertes liegt. Die Abweichung vom Trend entlang der Liniensegmente aufgrund des Aufnahmemodus beim Laserscanning lässt sich somit ausschließen.

Die übrigen Parameter sind für die Gewässerextraktion in Tabelle 5.4 aufgelistet. Hierbei handelt es sich zum einen um die Starttemperatur  $T_0$  im Simulated Annealing, welche jeweils auf eine Temperatur nahe Null abgekühlt wird. Die Abkühlung wird dabei entsprechend des Zusammenhangs  $T_t = T_0 \cdot k^t$  vorgenommen, wobei  $T_t$  die Temperatur in der jeweiligen Iteration  $t$  angibt. Der Abkühlungskoeffizient  $k$  wird so gesetzt, dass die Temperatur in der letzten Iteration ( $t_{max}$ ) einen Wert nahe Null

**Tabelle 5.4.:** Parametereinstellungen in den Experimenten für die Gewässernetzextraktion in den synthetischen Daten, den Daten aus den Wattgebieten und der Szene in Vorarlberg. Sofern unterschiedliche Werte in einzelnen Hierarchiestufen gesetzt sind, sind mehr als ein Wert pro Parameter aufgelistet. Die angegebene Anzahl an Iterationen wird pro Hierarchiestufe durchgeführt.

Parameter	Synth.	Watt	Gebiet 1+2	Vorarlb.	Vorarlb. A.
$T_0$	10	10	10	10	10
$t_{max}$	$1 \cdot 10^6$	$10 \cdot 10^6$	$2 \cdot 10^6$	$40 \cdot 10^6$	$10 \cdot 10^6$
$\lambda$	50	500	500	4000	500
$\beta$	0.13	0.15	0.35	0.1, 0.05	0.1, 0.05
$r$ [px]	16	20, 15, 15, 15	15	5, 6	5, 6
$p_h$	5	3	3	35,3	20,3
$p_o$	300	200	300	500	500, 400
$p_c$	100	80, 100	100	100	250, 150
$p_f$	50	50	50	50	50
$c_1$	50	150, 50, 20	50	0	0
$c_2$	4	4	4	12	12

erreicht. Die Anzahl der Iterationen  $t_{max}$  wird dabei für kleine Szenen geringer gewählt als für große Szenen. Die Intensität  $\lambda$  im Poisson-Punktprozess fließt bei der Berechnung der Kernelratio bei den Änderungen *Birth-and-Death* sowie *Split-and-Merge* in den Gleichungen 4.11, 4.14, 4.17 und 4.18 ein. Auch hier wird die Größe der Szene berücksichtigt und für große Datensätze ein größerer Wert als für kleinere Szenen gewählt. Der Faktor  $\beta$  gewichtet den Datenterm bezüglich des Priorterms (siehe Gleichung 4.1). Für Wattgebiete, bei denen die Gradienten an den Ufern geringer sind als in den Szenen aus Österreich, wird dieser Wert größer gewählt und der Datenterm dadurch im Vergleich zum Priorterm stärker gewichtet. Der Parameter  $r$  gibt den Suchradius für Knoten in der Nachbarschaft im *Birth-* sowie im *Merge*-Kernel an. Dieser wird so gewählt, dass die mäandrierenden Flüsse bzw. Priele bei den gewählten Auflösungsstufen der Eingangsdaten noch geeignet durch gerade Liniensegmente wiedergegeben werden. Bei  $p_h$ ,  $p_o$ ,  $p_c$  und  $p_f$  handelt es sich um die Gewichte des Datenterms der Homogenität sowie der Priorterme bezüglich der überlappenden Flächen, der Verbundenheit des Graphen und der Konsistenz der Fließrichtung im Netz, welche in den Gleichungen 4.4, 4.6, 4.7 und 4.8 berücksichtigt werden. Sie werden für alle Gebiete ähnlich groß gewählt. Die Parameter  $c_1$  und  $c_2$  fließen in die Berechnung der Datenterme in die Gleichungen 4.3 und 4.4 ein. Der Parameter  $c_1$  wird dabei nur für die Wattgebiete berücksichtigt, um zu verhindern, dass Knoten und Kanten auf den horizontalen Landflächen angenommen werden, an denen der Gradiententerm  $U_g$  nahe Null liegt. Der Parameter  $c_2$  wird für die Daten aus Österreich am höchsten gesetzt, da im Gegensatz zu den Wattgebieten größere Objekte wie Steine in den Flüssen beobachtet werden können und somit größere Höhengsprünge innerhalb des Netzes zu erwarten sind.

Die hierarchische Extraktion wird für die Testdaten aus dem Watt und aus Vorarlberg genutzt. Die Berechnung der Wahrscheinlichkeitskarte erfolgt im Fall der synthetischen Daten auf Basis eines Höhengschwellwertes. Für die übrigen Szenen wird die Krümmung aus Gleichung 4.20 bestimmt. In allen Fällen werden Schwellwerte  $\tau$  für die Höhen bzw. die Krümmung vorgegeben: (1) synthetische Daten:  $\tau_z = 1.05 \text{ m}$ , (2) Watt:  $\tau_\kappa = 150$ , Vorarlberg:  $\tau_\kappa = 150$ . Hierbei ist anzumerken, dass die Krümmung in der gesamten Szene jeweils auf einen Wertebereich von 0-255 skaliert wurde. In

**Tabelle 5.5.:** Parametereinstellungen in den Experimenten für die Liniennetzextraktion in Bildern.

Parameter	Fluss	Blatt	Retina	Kacheln
$T_0$	10	10	10	10
$t_{max}$	$10 \cdot 10^6$	$10 \cdot 10^6$	$10 \cdot 10^6$	$10 \cdot 10^6$
$\lambda$	500	500	500	500
$\beta$	0.3	0.3	0.3	0.3
$r$ [px]	12	10	12	10
$p_h$	30	30	30	30
$p_o$	200	300	300	300
$p_c$	50	50	50	50
$p_f$	20	0	0	50
$c_1$	50	50	0	50
$c_2$	4	4	4	4

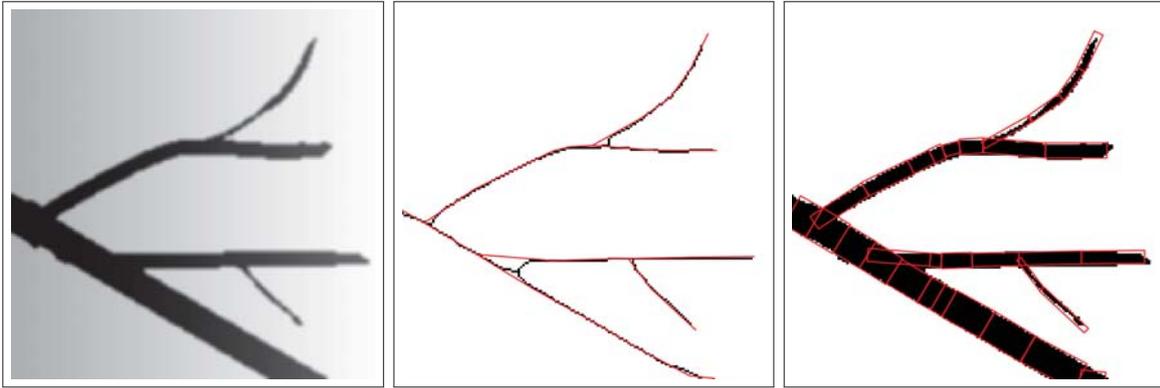
der Wahrscheinlichkeitskarte wird dann allen Pixel unterhalb des Höhen- bzw. oberhalb des Krümmungsschwellwertes der Wert  $p_1 = 1$  zugeordnet. Für alle übrigen Pixel wird die Wahrscheinlichkeit auf  $p_2 = 0.01$  gesetzt.

Für alle Bilder werden in der Regel ähnliche Parametereinstellungen gewählt (siehe Tabelle 5.5). Der Suchradius  $r$  wird in Abhängigkeit der Ausprägung des Netzes in den Daten leicht modifiziert. Zudem hat es sich als günstig erwiesen, den Term bezüglich der Fließrichtung  $p_f$  für die Bilder *Fluss* und *Kacheln* zu berücksichtigen. Dieser kann hierbei als Homogenitätskriterium der Grauwerte gedeutet werden. Da die Gradienten in der Szene *Retina* entlang einiger Ränder des Gefäßnetzes recht gering sind, ist die Konstante  $c_1$  zu Null gesetzt. Die Wahrscheinlichkeitskarte für die Bilder wird anhand von Schwellwerten für die Grauwerte  $g$  berechnet. Diese werden auf die Werte (1) Fluss:  $\tau_g = 70$ , (2) Blatt:  $\tau_g = 130$ , (3) Retina:  $\tau_g = 115$ , (4) Kacheln:  $\tau_g = 135$  gesetzt.

## 5.4. Evaluationsverfahren

Um den resultierenden Wald im *Forest Point Processes* quantitativ auszuwerten, werden zwei Evaluationsmethoden angewandt: (1) eine Linienevaluation und (2) eine pixelweise Evaluation. Die Linienevaluation wird bei der Bewertung der Ergebnisse der Gewässernetzextraktion verwendet. Hierfür werden die Mittelachsen des Netzes in den Referenzdaten mit den Kanten des Waldes (ohne Breiteninformation) evaluiert. Die pixelweise Evaluation wird für die Ergebnisse der Liniennetze in den Bildern genutzt, um mit der Auswertung der Vergleichsmethoden zur Liniennetzextraktion konsistent zu sein. Für diese liegt ein Binärbild als Referenzdaten vor. Um die Ergebnisse mit denen des *Forest Point Process* zu vergleichen, wird mit Hilfe der Segmente des Graphen ein Binärbild für das Ergebnis abgeleitet. Eine Übersicht zu beiden Vorgehensweisen ist in Abbildung 5.4 skizziert.

**Linienevaluation:** Hierfür wird das Verfahren von Wiedemann et al. [1998] genutzt, welches ermöglicht, die Genauigkeiten bezüglich einer Referenzlinie anzugeben. Hierbei wird um jede Linie ein Puffer gelegt, wobei mit  $b_{ref}$  der Puffer um die Referenzlinie und mit  $b_{erg}$  der Puffer um die Ergebnislinie bezeichnet wird. Anschließend werden entlang der Ergebnislinie Punkte in regelmäßigen Abständen  $\Delta x$  abgegriffen, und es wird senkrecht zur Linie nach korrespondierenden Punkten auf der



**Abbildung 5.4.:** Für die Evaluation eines Ergebnisses bezüglich der Eingangsdaten (links) werden zwei Methoden angewandt. In der Linienevaluation werden die Kanten im Wald, welche den roten Linien entsprechen, mit gegebenen Referenzmittellachsen verglichen (Mitte). In der pixelweisen Evaluation werden die Pixel innerhalb der Segmente, die durch die roten Rechtecke gegeben sind, im Wald hinsichtlich einer gegebenen Referenzfläche des Liniennetzes ausgewertet (rechts).

Referenzlinie gesucht (siehe Abbildung 5.5). Hierbei werden nur Punkte berücksichtigt, die innerhalb des Puffers  $b_{erg}$  liegen. Zudem erfolgt die Suche von der Referenzlinie aus nach korrespondierenden Punkten auf der Ergebnislinie innerhalb von  $b_{ref}$ . Für den Abstand der Punkte  $\Delta x$  entlang der Linien wird jeweils die Breite eines Pixels in den Eingangsdaten gewählt. Aus der Zahl der korrespondierenden Punkte können anschließend Qualitätsmaße abgeleitet werden. Im Folgenden wird die Ergebnislinie anhand der *Vollständigkeit*  $V$ , *Korrektheit*  $K$  und *Qualität*  $Q$  bewertet. Die Vollständigkeit ist ein Maß dafür, mit welchem Anteil die Linien des Referenznetzes im Ergebnis enthalten sind. Die Korrektheit gibt an, mit welchem Anteil die Linien im Ergebnis richtig extrahiert wurden. Die Qualität ergibt sich aus der Kombination beider Maße und kann für ein Ranking einzelner Ergebnisse genutzt werden. Die drei Qualitätsmaße werden über

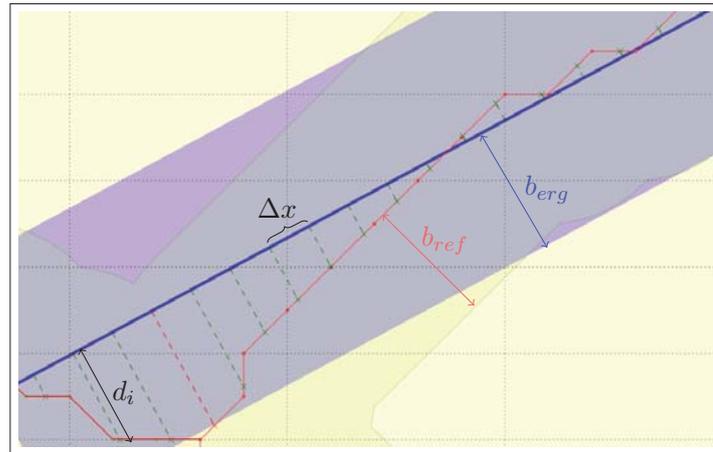
$$V = \frac{\text{Anzahl der Punkte der Referenzlinien innerhalb } b_{erg}}{\text{Anzahl aller Punkte der Referenzlinien}}, \quad (5.1)$$

$$K = \frac{\text{Anzahl der Punkte der Ergebnislinien innerhalb } b_{ref}}{\text{Anzahl aller Punkte der Ergebnislinien}}, \quad (5.2)$$

$$Q = \frac{K \cdot V}{K + V - K \cdot V} \quad (5.3)$$

bestimmt. Hierbei fließen die zuvor eingeführten Punkte ein, welche im regelmäßigen Abstand  $\Delta x$  abgegriffen werden. Aufgrund der gleichabständigen Wahl der Punkte beziehen sich die Maße der Vollständigkeit und der Korrektheit auf die Länge des Netzes. Zudem ist ein Maß für die geometrische Genauigkeit abgeleitet. Hierfür wird der *Root Mean Square Error* (*RMS*) der Distanzen  $d_i$  zwischen den Punkten der Ergebnislinien und den korrespondierenden Punkten der Referenzlinien innerhalb des Puffers  $b_{ref}$  berechnet (siehe Abbildung 5.5). Die geometrische Genauigkeit ergibt sich dann über die mittlere quadratische Distanz der Linien,

$$RMS = \sqrt{\frac{1}{n_p} \sum_{i=1}^{n_p} d_i^2}, \quad (5.4)$$



**Abbildung 5.5.:** Bei der Linienevaluation wird die Ergebnislinie (blau) im Vergleich zur Referenzlinie (rot) ausgewertet. Hierfür wird in regelmäßigen Abständen  $\Delta x$  nach korrespondierenden Punkten gesucht. Liegen die Punkte innerhalb des Puffers  $b_{erg}$  (wie durch die grün gestrichelten Linien symbolisiert), werden sie als korrekt zugeordnet betrachtet. Andernfalls gilt ein Punkt als nicht korrekt zugeordnet (rot gestrichelte Linie links unten). Die korrekt zugeordneten Punkte werden darüber hinaus zur Berechnung einer geometrischen Genauigkeit genutzt, welche aus den Distanzen  $d_i$  zwischen Ergebnis und Referenz entlang der grün gestrichelten Linien ermittelt wird.

wobei  $n_p$  die Anzahl der Punkte der Ergebnislinien innerhalb  $b_{ref}$  angibt. Die Puffergrößen  $b_{erg}$  und  $b_{ref}$  werden für die synthetischen Daten auf 1 m, für das Testgebiet im Watt auf 10 m und für die Daten in Vorarlberg auf 15 m gesetzt. Der Puffer für die synthetischen Daten wird dabei deutlich kleiner gewählt, da es sich hierbei um ein idealisiertes Prielnetz handelt, bei dem ein besseres Extraktionsergebnis im Vergleich zu den echten Daten zu erwarten ist. Die Puffergröße für die Daten aus Vorarlberg orientiert sich an dem von Vetter & Mandlburger [2014] für dasselbe Testgebiet genutztem Wert. Da im Prielnetz viele schmale Priele enthalten sind, wird die Puffergröße im Vergleich hierzu etwas geringer gewählt.

**Pixelweise Evaluation:** Bei der pixelweisen Evaluation liegt als Referenz ein Binärbild vor, in dem jedes Pixel der Klasse *Liniennetz* oder *Hintergrund* zugeordnet ist. Aus dem Ergebnis des *Forest Point Process* wird ebenfalls ein Binärbild abgeleitet. Ein Pixel wird hierbei als zum Liniennetz zugehörig betrachtet, wenn dessen Mittelpunkt innerhalb der Ränder eines der Liniensegmente des Waldes liegt. Aus dem Vergleich beider Binärbilder können die quantitativen Maße *Vollständigkeit V*, *Korrektheit K* und *Qualität Q* abgeleitet werden, die sich über

$$V = \frac{\text{Anzahl korrekt erkannter Liniennetzpixel}}{\text{Anzahl aller Liniennetzpixel}}, \quad (5.5)$$

$$K = \frac{\text{Anzahl korrekt erkannter Liniennetzpixel}}{\text{Anzahl aller als Liniennetz erkannten Pixel}} \quad (5.6)$$

berechnen lassen und die sich somit auf die korrekt klassifizierte Fläche beziehen. Die Qualität  $Q$  wird über Gleichung 5.3 bestimmt. Ein Maß für die geometrische Genauigkeit wird für die pixelweise Evaluation nicht berechnet.



## 6. Ergebnisse und Diskussion

In diesem Kapitel werden die durchgeführten Experimente sowie deren Ergebnisse vorgestellt und diskutiert. Zunächst wird eine Analyse des Modells vorgenommen, in der das Konvergenzverhalten, das Modell der Energiefunktion sowie die Wiederholbarkeit der Experimente näher untersucht werden (Abschnitt 6.1). Anschließend wird die Eignung des *Forest Point Process* für Gewässernetze in unterschiedlichen Geländeformen evaluiert (Abschnitt 6.2). Die Ergebnisse sind denen aus Standardverfahren in der Forschung gegenübergestellt. Zudem wird der Einfluss der Parameter auf die Ergebnisse analysiert und eine Anwendbarkeit des Verfahrens für Zeitreihen bewertet. Abschnitt 6.3 zeigt die Übertragbarkeit des *Forest Point Process* auf Liniennetze in Bildern.

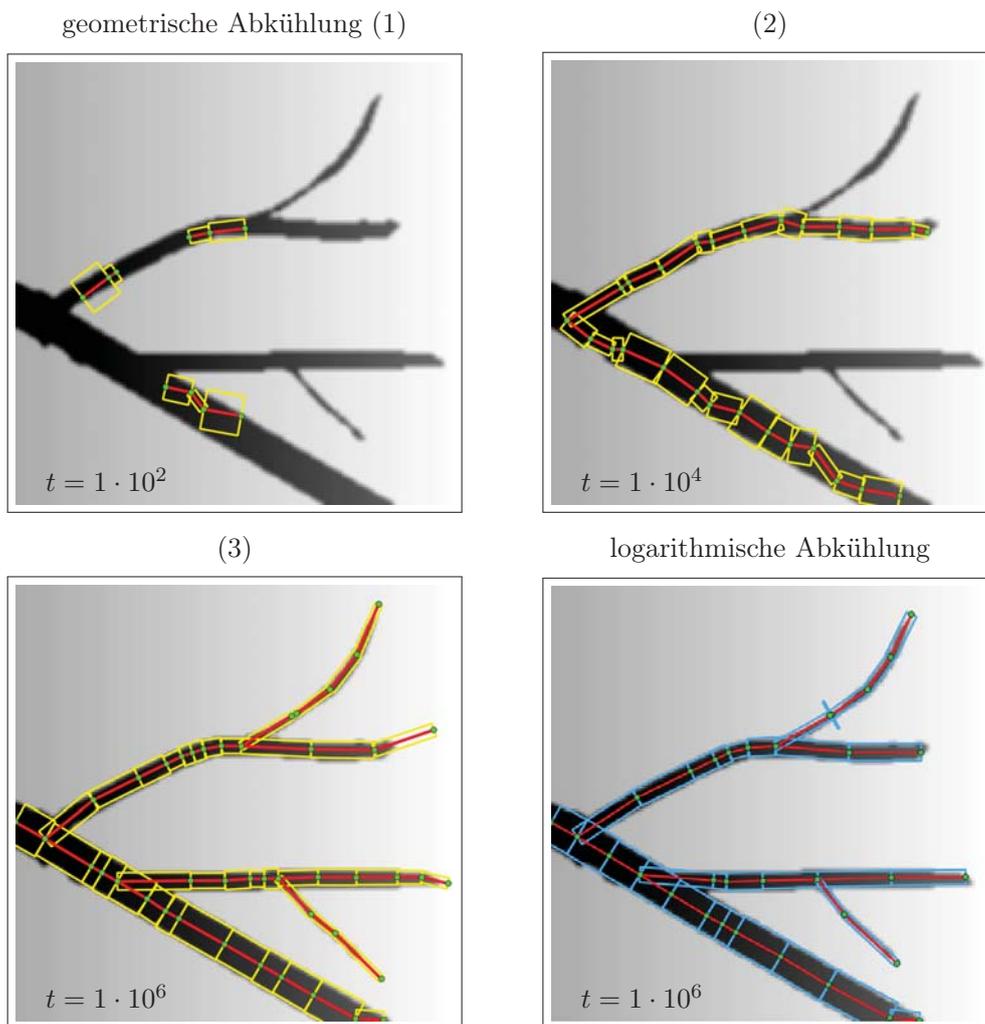
### 6.1. Analyse des Modells

Zunächst wird der Fragestellung nachgegangen, inwiefern sich das Modell des *Forest Point Process* für die Extraktion von Liniennetzen eignet. Hierfür werden überwiegend die synthetischen Daten verwendet. Diese werden genutzt um (1) den Einfluss des Abkühlungsverfahrens (*Simulated Annealing*-Ansatz) auf das Ergebnis zu untersuchen, (2) aufzuzeigen, welchen Einfluss die einzelnen Energieterme im Modell haben und (3) zu untersuchen, inwiefern das Generieren der Zufallszahlen im Sampling auf die Ergebnisse wirkt.

#### 6.1.1. Einfluss des Abkühlungsverfahrens

**Experiment:** Während des Samplings wird die Energiefunktion  $U$  minimiert. Anhand der synthetischen Daten soll zunächst aufgezeigt werden, wie diese gegen das Optimum konvergiert. Zudem werden die Ergebnisse unterschiedlicher Abkühlungsverfahren im *Simulated Annealing* gegenübergestellt. Hierbei wird zum einen eine logarithmische Abkühlung mit  $T_t = \frac{T_0}{\log(2+t)}$  und zum anderen eine Abkühlung mit  $T_t = T_0 \cdot k^t$ , im Folgenden als geometrische Abkühlung bezeichnet, gewählt.

**Ergebnis:** In dem Samplingprozess werden dem Wald nach und nach Knoten und Kanten hinzugefügt oder daraus entfernt sowie die Parameter des Graphen modifiziert. Abbildung 6.1 zeigt am Beispiel der synthetischen Daten für die geometrische Abkühlung, wie sich der Wald dabei aufbaut. Nach ungefähr  $760 \cdot 10^3$  Iterationen ist das Prielnetz vollständig mit Segmenten bedeckt. Hierbei stimmen die Konturen der Priele gut mit den Segmenträndern im Graphen überein. Zudem ist der Graph vollständig verbunden und setzt sich somit aus einem einzelnen Baum zusammen. Die Energiefunktion sinkt hierbei zunächst stark ab, bis der Großteil der Priele nach etwa  $45 \cdot 10^3$  Iterationen detektiert ist. Anschließend konvergiert die Funktion langsamer gegen das Minimum (Abbildung 6.2). Tabelle 6.1



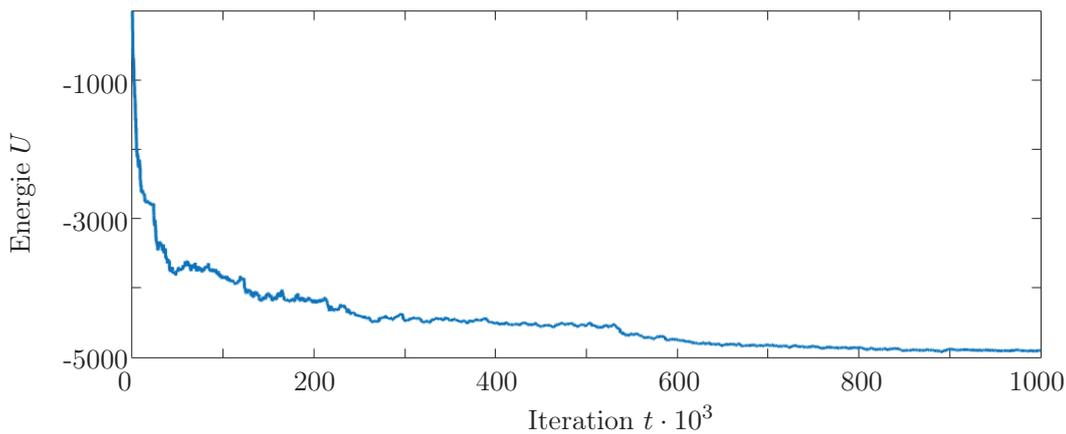
**Abbildung 6.1.:** Während des Samplings baut sich der Graph nach und nach auf, hier am Beispiel der synthetischen Daten aufgezeigt. Die geometrische Abkühlung (zu unterschiedlichen Iterationen  $t$  dargestellt) im *Simulated Annealing* führt dabei zu ähnlichen Ergebnissen wie die logarithmische Abkühlung.

gibt die Qualitätsmaße für dieses Ergebnis an und stellt sie denen einer logarithmischen Abkühlung gegenüber. In beiden Fällen werden ähnliche Qualitätsmaße mit  $V_{geom} = 99.6\%$  bzw.  $V_{log} = 98.8\%$ ,  $K_{geom} = 89.0\%$  bzw.  $K_{log} = 94.0\%$  und  $Q_{geom} = 88.6\%$  bzw.  $Q_{log} = 92.9\%$  erzielt. Unterschiede können in erster Linie mit den Differenzen der Segmente an den Enden der Priele erklärt werden, die für das Ergebnis der geometrischen Abkühlung leicht über die tatsächlichen Priele hinausragen. Für die geometrische Genauigkeit werden ähnliche Werte von  $RMS_{geom} = 0.69\text{ px}$  bzw.  $RMS_{log} = 0.66\text{ px}$  erreicht.

Der Vergleich der Laufzeiten für beide Ergebnisse zeigt, dass die geometrische Abkühlung aufgrund der geringeren Anzahl an Iterationen deutlich schneller durchgeführt wird. Das Ergebnis ist hierbei mit einem Faktor 4.6 schneller erreicht. Ein ähnliches Resultat ergibt sich für die Anwendung beider Abkühlungsverfahren auf echte Daten. Für *Gebiet 1* im Wattenmeer erfolgt die geometrische

**Tabelle 6.1.:** Genauigkeitsergebnisse (Vollständigkeit  $V$ , Korrektheit  $K$ , Qualität  $Q$ , geometrische Genauigkeit  $RMS$ ) in der Linienevaluation für unterschiedliche Datensätze und Abkühlungsverhalten während des Samplings.

Datensatz	Abkühlung	V [%]	K [%]	Q [%]	RMS [px]	Zeit [min]
synthetisch	geometrisch	99.6	89.0	88.6	0.69	2.5
	logarithmisch	98.8	94.0	92.9	0.66	11.5
Watt (Gebiet 1)	geometrisch	72.7	94.4	69.7	2.67	7.9
	logarithmisch	75.3	91.4	70.3	3.02	35.3



**Abbildung 6.2.:** Verlauf der Energie  $U$  während des Samplingprozesses am Beispiel der geometrischen Abkühlung.

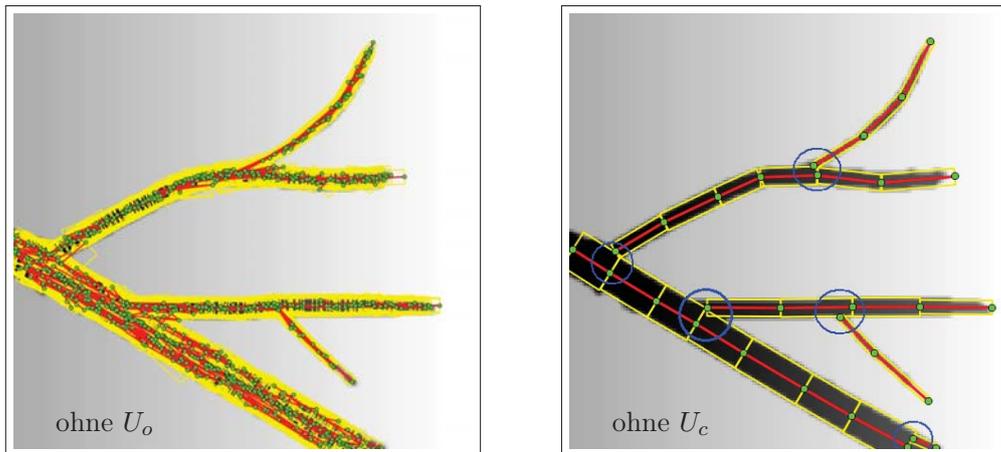
Abkühlung im Samplingprozess um den Faktor 4.5 schneller als die logarithmische Abkühlung, bei vergleichbaren Qualitätsraten von  $Q_{geom} = 69.7\%$  und  $Q_{log} = 70.3\%$ .

**Diskussion:** Die Ergebnisse veranschaulichen, dass sich das Modell der aufgestellten Energiefunktion eignet, um ein Prielnetz in synthetischen Daten zu beschreiben, Vollständigkeits- und Korrektheitsraten von  $> 98\%$  bzw.  $\geq 89\%$  werden hierbei erzielt. Das Ergebnis lässt sich somit als nahezu optimal bezüglich der gewählten Qualitätskriterien einstufen. Der Vergleich zweier Abkühlungsverfahren macht deutlich, dass im *Simulated Annealing* insbesondere für die echten Daten ähnliche Ergebnisse für den Graphen bei Verwendung einer geometrischen und einer logarithmischen Abkühlung erzielt werden. Aufgrund der geringeren Laufzeit wird für die Ausführung der weiteren Experimente die geometrische Abkühlung gewählt.

### 6.1.2. Einfluss der Energieterme

**Experiment:** Die im Sampling konvergierende Energiefunktion  $U$  setzt sich aus fünf Termen zusammen (siehe Gleichung 4.1). Im Folgenden soll die Relevanz dieser Terme untersucht werden. Hierzu wird jeweils einer der Terme vernachlässigt und der resultierende Wald des *Forest Point Process* visuell und quantitativ ausgewertet.

**Ergebnis:** In allen Fällen verschlechtert sich die Qualität  $Q$  der Ergebnisse, sofern einer der Terme im Modell nicht berücksichtigt wird (siehe Tabelle 6.2). Wird das Vorwissen, dass Segmente sich nicht



**Abbildung 6.3.:** Ohne die Bestrafung von Überlappungen der Segmente im Datenterm  $U_o$  setzt sich der Wald aus zu vielen Segmenten zusammen (links). Werden unzusammenhängende Graphen im Priorterm  $U_c$  nicht bestraft, bleibt der Wald an mehreren Stellen unverbunden (blau markiert, rechts).

überlappen in Form des Priorterms  $U_o$  vernachlässigt, häufen sich eine Vielzahl von Segmenten im Prielnetz an (Abbildung 6.3). Der Graph enthält hierbei 843 Knoten, während die Anzahl der Knoten lediglich bei 43 liegt, sofern  $U_o$  berücksichtigt wird. Die Verschlechterung der Graphkonfiguration wird jedoch nur im visuellen Ergebnis deutlich, in welchem die Überlagerung einer Vielzahl von Segmenten zu erkennen ist. Die Qualitätsmaße hingegen verschlechtern sich nur geringfügig bzw. nehmen im Fall der Vollständigkeit sogar zu. Durch die zunehmende Anzahl an eingefügten Kanten und Knoten steigt die Anzahl der angenommenen Vorschläge im Sampling. Eine vorgeschlagene Konfiguration wird hierbei für etwa 10 % der Iterationen angenommen (siehe Tabelle 6.2). Für die übrigen getesteten Kombinationen an Termen liegt diese Rate lediglich bei etwa 3 – 7 %. Der Priorterm bezüglich der Verbundenheit des Graphen  $U_c$  hilft, um einen einzelnen zusammenhängenden Graphen als Ergebnis zu erhalten. Wird dieser im Modell vernachlässigt, setzt sich der Graph stattdessen aus sechs Bäumen zusammen (Abbildung 6.3). Insbesondere beim Zusammenfluss mehrerer Priele ist der Wald unverbunden. Hier ist zu vermuten, dass die Bestrafung überlappender Flächen die Verbindung verhindert.

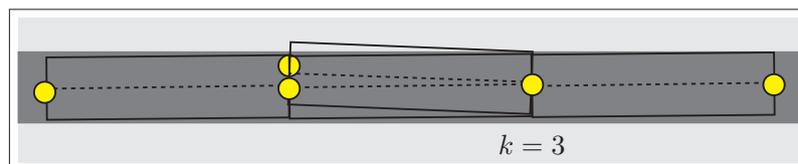
Der Priorterm  $U_f$  und der Datenterm  $U_h$ , mit welchen Inkonsistenzen bezüglich der Fließrichtung bzw. inhomogene Höhen im Querprofil bestraft werden, führen ebenfalls zu einer Verbesserung der Qualitätsmaße. Der Einfluss dieser Terme wird im Zusammenhang mit den echten Daten in Abschnitt 6.2.2 noch ausführlicher diskutiert. Das Streichen des Datenterms  $U_g$  erweist sich nicht als sinnvoll. Die Reduktion des Wertes der Energiefunktion wird in erster Linie durch negative Gradientenbeträge im Datenterm  $U_g$  verursacht. Für die absoluten Werte der weiteren Terme gilt:  $U_h \geq 0$ ,  $U_o \geq 0$ ,  $U_c \geq 0$  und  $U_f \geq 0$ . Lediglich durch den relativen Vergleich bezüglich einer vorherigen Konfiguration können sich auch für diese Terme negative Werte ergeben. Zu Beginn des Samplingprozesses, wenn große Sprünge beim Durchsuchen des Objektraums im *Simulated Annealing* zugelassen werden, werden einige Knoten und Kanten auch ohne Berücksichtigung von  $U_g$  eingefügt. Mit zunehmender Iteration werden diese jedoch wieder aus dem Wald entfernt. Im Endergebnis ist kein Knoten oder keine Kante enthalten.

**Tabelle 6.2.:** Genauigkeitsergebnisse (Vollständigkeit  $V$ , Korrektheit  $K$ , Qualität  $Q$ , geometrische Genauigkeit  $RMS$ ) für die synthetischen Daten. Zudem ist der prozentuale Anteil der angenommenen Vorschläge bezogen auf die Gesamtzahl der Iterationen im Sampling angegeben.

Method	V [%]	K [%]	Q [%]	RMS [px]	Annahme [%]
alle Terme	99.6	89.0	88.6	0.69	3.0
ohne Term Gradienten ( $U_g$ )	-	-	-	-	-
ohne Term inhom. Höhen ( $U_h$ )	92.3	89.7	83.4	0.60	7.2
ohne Term Überlappungen ( $U_o$ )	100.0	87.0	87.0	0.97	10.3
ohne Term Verbundenheit ( $U_c$ )	92.3	89.6	83.4	0.60	2.7
ohne Term inkonsist. Fließr. ( $U_f$ )	91.1	89.6	82.4	0.68	3.8

**Diskussion:** Die Ergebnisse zeigen, dass das Modell für die Energiefunktion sinnvoll gewählt ist. Wird jeweils einer der fünf Daten- und Priorterme aus dem Modell entfernt, verschlechtert sich in allen Fällen die Genauigkeit. Das beste Ergebnis wird erst beim Zusammenwirken aller Terme erzielt. Weitere Kombination an Termen werden daher nicht evaluiert. Als kritisch kann insgesamt betrachtet werden, dass sich beim Zusammenfluss mehrerer Priele die Terme  $U_o$  und  $U_c$  widersprechen. Entweder wird hier die Überlappung der Segmente oder die Unverbundenheit des Graphen bestraft. Eine denkbare Lösung ist es, die Bestrafung überlappender Flächen im Bereich von Knoten des Grades  $k \geq 3$  auszuschließen. Durchgeführte Experimente hierzu haben jedoch gezeigt, dass auf diese Weise eine Vielzahl ungewollter Konfigurationen in der Art ermöglicht werden, wie sie Abbildung 6.4 veranschaulicht. Hier werden Knoten des Grads  $k = 3$  auch abseits von Kreuzungen und entlang geradliniger Flussläufe zugelassen. Die Ursache hierfür ist der Datenterm, der für jedes der Segmente eine Reduktion des Wertes der Energiefunktion bewirkt. Abhilfe könnte ein darüber hinaus integriertes Winkelkriterium verschaffen, welches inzidente Kanten mit geringem Zwischenwinkel an Knoten des Grads  $k = 3$  ausschließt. Alternativ ist es denkbar, im Überlappungsterm der Priorenergie in Gleichung 4.6 eine gewisse Überlappung zuzulassen und die Überlappungsfläche von zwei Segmenten mit  $\max(0, \text{relative Fläche} - 5\%)$  zu bestrafen.

Das durchgeführte Experiment verdeutlicht zudem, dass die gewählten Qualitätsmaße in Tabelle 6.2 nicht ausschließlich für eine Beurteilung des Waldes herangezogen werden können. Eine nicht geeignete Repräsentation des Prielnetzes, wie sie bei Vernachlässigung des Priorterms  $U_o$  bezüglich der Überlappungsflächen entsteht, spiegelt sich hierin nicht wider. Hier ist es denkbar, topologische Genauigkeitsmaße in zukünftigen Untersuchungen einzuführen, wie sie beispielsweise in Wiedemann [2002] vorgeschlagen werden.



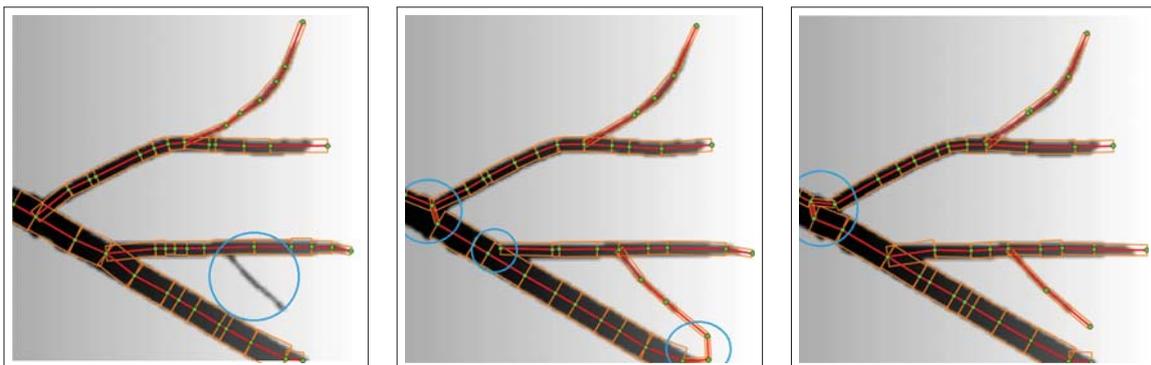
**Abbildung 6.4.:** Wird die Bestrafung der Überlappungen von Segmenten ausgeschlossen, die mit einem Knoten des Grades  $k = 3$  verbunden sind, enthält das Ergebnis eine zu große Anzahl von Segmenten. Aufgrund der Verringerung des Energiewertes durch den Datenterm werden mehrere Segmente nahe des Randes des Liniennetzes vorgeschlagen.

### 6.1.3. Einfluss der Ziehung von Zufallszahlen

**Experiment:** Der *Forest Point Process* baut an vielen Stellen auf der Ziehung von Zufallszahlen auf. Um deren Einfluss auf das Ergebnis zu überprüfen, wird das Experiment für die synthetischen Daten 100 mal wiederholt. Aus den Ergebnissen wird ein Maß für die innere geometrische Genauigkeit des *Forest Point Process* abgeleitet. Hierfür wird die Referenzmittelachse in regelmäßigen Abständen von  $\Delta x = 1 px$  abgetastet. Senkrecht hierzu wird nach korrespondierenden Punkten auf den Kanten in den Ergebniswäldern aller 100 Experimente gesucht. Für jeden abgetasteten Punkt auf der Referenzmittelachse wird dann die Standardabweichung der Positionen aller korrespondierenden Punkte in den Ergebnissen bestimmt. Über alle Standardabweichungen wird anschließend ein Mittelwert gebildet, welcher als Maß für die innere Genauigkeit betrachtet wird.

**Ergebnis:** Wird das Experiment wiederholt, wobei in jeder Wiederholung unterschiedliche Zufallszahlen generiert werden, ergibt sich für alle Durchführungen eine ähnliche Anzahl an Knoten und Kanten im Ergebniswald (siehe Tabelle 6.3). Die Energiewerte in der letzten Iteration variieren dabei leicht. In den Graphkonfigurationen lassen sich geringe Unterschiede erkennen (siehe Abbildung 6.5). In einigen Fällen wird einer der kleinen Priele nicht detektiert. Die Gesamtenergie  $U$  ist in diesen Fällen größer als bei den Fällen, in denen dieser Teil des Netzes erkannt wurde. Auch kommt es vor, dass topologisch inkorrekte Verbindungen akzeptiert werden (5 % der Ergebnisse) oder dass zu schmale Segmente zur Beschreibung des Netzes gewählt sind (27 % der Ergebnisse), welche die Priele in ihrer Breite nicht vollständig abdecken. Für die innere Genauigkeit, der Streuung der Kanten um die Referenzmittelachse ergibt sich ein Wert von  $0.38 px$ . Dieses Ergebnis wird als gute Genauigkeit für die Zuverlässigkeit des Experiments eingestuft.

**Diskussion:** Bei mehrmaliger Wiederholung des Experiments können ähnliche Ergebnisse erzielt werden, wobei zum Teil leichte Variationen in den Graphkonfigurationen des Ergebnisses auftreten. Eine gewisse Variation ist dem Einfluss bei der Generierung der Zufallszahlen zuzuschreiben, welche sich in der inneren Genauigkeit von  $0.38 px$  widerspiegelt.



**Abbildung 6.5.:** Bei Wiederholung des Experiments ergeben sich bedingt durch die Ziehung von Zufallszahlen im Sampling zum Teil andere Konfigurationen des Waldes, hier anhand von drei Beispielen aufgezeigt. In den blau umrandeten Bereichen weichen diese vom gewünschten Ergebnis ab: es fehlt einer der Zuflüsse (links), das Netz ist inkorrekt verbunden (Mitte) oder setzt sich aus zu schmalen Segmenten zusammen (Mitte und rechts).

**Tabelle 6.3.:** Variation der Ergebnisse bei Wiederholung des Experiments mit unterschiedlichen Zufallszahlen.

Parameter	Mittelwert	Standardabweichung
Anzahl Knoten	37.6	2.6 (6.9%)
Anzahl Kanten	36.1	2.6 (7.2%)
Gesamtenergie $U$	-4720.4	126.3 (2.6%)

## 6.2. Extraktion von Gewässernetzen

Die Wahl der Energiefunktion im Modell ist durch die Anwendung für Gewässernetze motiviert. Anhand von echten Daten wird daher experimentell untersucht, (1) inwiefern der *Forest Point Process* geeignet ist, um Gewässernetze in DGMs mit unterschiedlichen Geländeformen zu extrahieren, (2) welchen Einfluss die Wahl der Parameter im Modell dabei hat und (3) wie das Verfahren im Vergleich zu Standardverfahren für diese Aufgabenstellung abschneidet. Zusätzlich wird eine Anwendung für Daten in Form einer Zeitreihe vorgestellt.

### 6.2.1. Anwendung für verschiedene Geländeformen

**Experiment:** Im Folgenden soll untersucht werden, wie gut sich der *Forest Point Process* für unterschiedliche Geländeformen eignet. Dies wird anhand der echten Daten aus dem Wattenmeer sowie der Szene aus Vorarlberg überprüft. Für beide Datensätze wird eine hierarchische Extraktion durchgeführt, d.h. es werden zunächst die breiten Flüsse in einer geringen Auflösungsstufe des DGM und anschließend die schmalere Flüsse in Eingangsdaten höherer Auflösung gesucht. Dabei werden folgende Hierarchiestufen verwendet: (1) gesamte Wattzone: 20 m, 10 m, 5 m, 2 m, (2) Gebiet 1 im Watt: 2 m, 1 m und (3) Vorarlberg gesamter Bereich und Ausschnitt: 10 m, 5 m. Die Ergebnisse werden quantitativ ausgewertet.

**Ergebnis:** Die Qualitätsmaße für die Testgebiete sind in Tabelle 6.4 angegeben. Für *Gebiet 1* im Watt können die Genauigkeiten insgesamt als hoch eingestuft werden. Hier betragen die Vollständigkeit, Korrektheit und Qualität  $V = 72.7\%$ ,  $K = 94.4\%$  und  $Q = 69.7\%$ . Die größeren Priele sind vollständig mit Liniensegmenten des Graphen bedeckt (siehe Abbildung 6.6). Zudem stimmen die Ränder der Segmente im Graphen gut mit der Kontur der Priele überein. Lediglich am oberen Bildrand werden die Priele im Bereich einer Sandbank nicht erkannt (siehe Abbildung 6.7). Diese passen nicht zu dem Modell des azyklischen Graphen. Zudem werden sehr feine Strukturen nicht gefunden. Bei den gewählten Parametereinstellungen scheinen die geringen Gradientenbeträge an den Ufern der kleinen Priele zu keiner ausreichenden Reduktion des Wertes der Energiefunktion zu führen. Die geometrische Genauigkeit lässt sich mit  $RMS = 2.75 px$  angeben. Im Vergleich zu den weiteren Testgebieten ist die geometrische Genauigkeit geringer. Dies kann unter anderem damit erklärt werden, dass in einigen Bereichen die Segmente aufgrund schwach ausgeprägter Gradienten auf einer Seite zu breit geschätzt sind und die Mittelachse daher einen Versatz zur Referenz aufweist (siehe Abbildung 6.7).

Für die gesamte Szene aus dem Watt zeigt sich, dass eine Vielzahl der Priele in den unterschiedlichen Hierarchiestufen extrahiert werden (Abbildung 6.8). Innerhalb der einzelnen Zuflüsse sind die Priele in der Regel vollständig miteinander verbunden. Jedoch ist die Verbundenheit über die Hierarchiestufen hinweg oft nicht gegeben. Zudem werden erneut einige kleine Zuflüsse nicht erkannt, was sich in einer vergleichsweise geringen Vollständigkeit von  $V = 50.6\%$  bei einer recht hohen Korrektheit von  $K = 78.2\%$  niederschlägt. Wird anstelle der Linienevaluation die pixelweise Evaluation für die Auswertung angewendet, steigt insbesondere die Vollständigkeit stark an und beträgt  $V = 79.2\%$  bei einer Korrektheit von  $K = 80.3\%$ . Der Anstieg kann damit erklärt werden, dass die großen Priele, deren Flächen einen hohen Anteil im gesamten Priernetz einnehmen, weitestgehend extrahiert sind.

Für den Ausschnitt in Vorarlberg wird die Bregenzer Ach, der größte Fluss der Szene, in der ersten Hierarchiestufe vollständig extrahiert (siehe Abbildung 6.9). Auch von den übrigen Flüssen in der Szene werden viele erkannt, was zu recht guten Genauigkeiten von  $V = 75.4\%$ ,  $K = 73.6\%$  und  $Q = 59.4\%$  führt ( $\beta = 0.04$ ). Die geometrische Genauigkeit ergibt sich mit  $0.94\text{ px}$ . Wird das Gewicht für den Datenterm erhöht ( $\beta = 0.05$ ), steigt die Anzahl der extrahierten Flüsse,  $V = 85.9\%$ . Jedoch verschlechtert sich die Korrektheit der Ergebnisse,  $K = 68.2\%$  (siehe Tabelle 6.4), da nicht alle der extrahierten Segmente einem Flussabschnitt entsprechen. Ein ähnliches Ergebnis ergibt sich, sofern als Eingangsdaten ein DGM mit höherer Auflösung gewählt wird. Wird die hierarchische Extraktion mit einem DGM mit  $5\text{ m}$  Auflösung im ersten Schritt und mit  $1\text{ m}$  Auflösung im zweiten Schritt durchgeführt, steigt die Vollständigkeit auf  $V = 87.7\%$ . Jedoch verringert sich die Korrektheit auf  $K = 55.4\%$ . Dies kann damit erklärt werden, dass eine größere Zahl an Kanten und Knoten im Sampling angenommen werden, welche jedoch vielfach nicht mit dem Referenzliniennetz übereinstimmt.

In der gesamten Szene *Vorarlberg* werden bei einer Auflösung des DGM von  $5\text{ m}$  bzw.  $10\text{ m}$  von dem Flussnetz mit einer Gesamtlänge von  $247.3\text{ km}$  mit Hilfe des *Forest Point Process*  $156.1\text{ km}$  ( $V = 64.5\%$ ,  $\beta = 0.05$ ) extrahiert. Als nachteilig kann dabei herausgestellt werden, dass in Bereichen mit starken Höhenunterschieden zu viele Zuflüsse der Bregenzer Ach erkannt werden (siehe Abbildung 6.10). Bei näherer Betrachtung dieser Gebiete ist zu erkennen, dass hier Geländeeinschnitte ähnlich denen eines Flussnetzes verlaufen. Da diese nicht regelmäßig von Wasser durchlaufen sind, werden sie im Referenznetz nicht als Flüsse ausgegeben. Eine ähnliche Beobachtung wird in den Arbeiten von Vetter & Mandlbürger [2014] bei Verwendung eines *Flow Routing*-Ansatzes gemacht, bei denen für dieselben Eingangsdaten ebenfalls eine zu hohe Anzahl an Flüssen erkannt werden. Die Modelle können nicht zwischen trockenen und von Wasser durchflossenen Flussläufen unterscheiden. Des weiteren fällt im Ergebnis auf, dass im Stadtgebiet von Bregenz sowie im nordöstlichen Bildausschnitt eine Vielzahl von Flüssen nicht extrahiert sind (siehe Markierung in Abbildung 6.10). Hier treten viele kleine Flüsse mit geringen Gradientenbeträgen an den Flussufern auf. Im Stadtbereich lässt die Auswertung der Luftbilder zudem vermuten, dass teilweise künstliche Uferbefestigungen vorliegen. Die Querprofile der Flüsse unterscheiden sich dann von denen der natürlichen Flussläufe. Eine Extraktion mit einheitlichen Parametereinstellungen für die gesamte Szene scheint in beiden Fällen nicht möglich zu sein. Insgesamt können die Ergebnisse dennoch als relativ gut eingestuft werden, was der Vergleich mit alternativen Verfahren zur Gewässernetzextraktion in Abschnitt 6.2.3 verdeutlicht.

**Diskussion:** Die Ergebnisse zeigen, dass der *Forest Point Process* sowohl in Gebieten mit horizontalem Geländeverlauf im Watt als auch in bergigem Gelände erfolgreich für die Extraktion von

**Tabelle 6.4.:** Genauigkeitsergebnisse der **Linienevaluation** (Vollständigkeit  $V$ , Korrektheit  $K$ , Qualität  $Q$ , geometrische Genauigkeit  $RMS$ ) in Abhängigkeit der Gewichtung  $\beta$  zwischen der Daten- und Priorenergie. Für das DGM ist hierbei die Rasterweite in den einzelnen Hierarchiestufen angegeben.

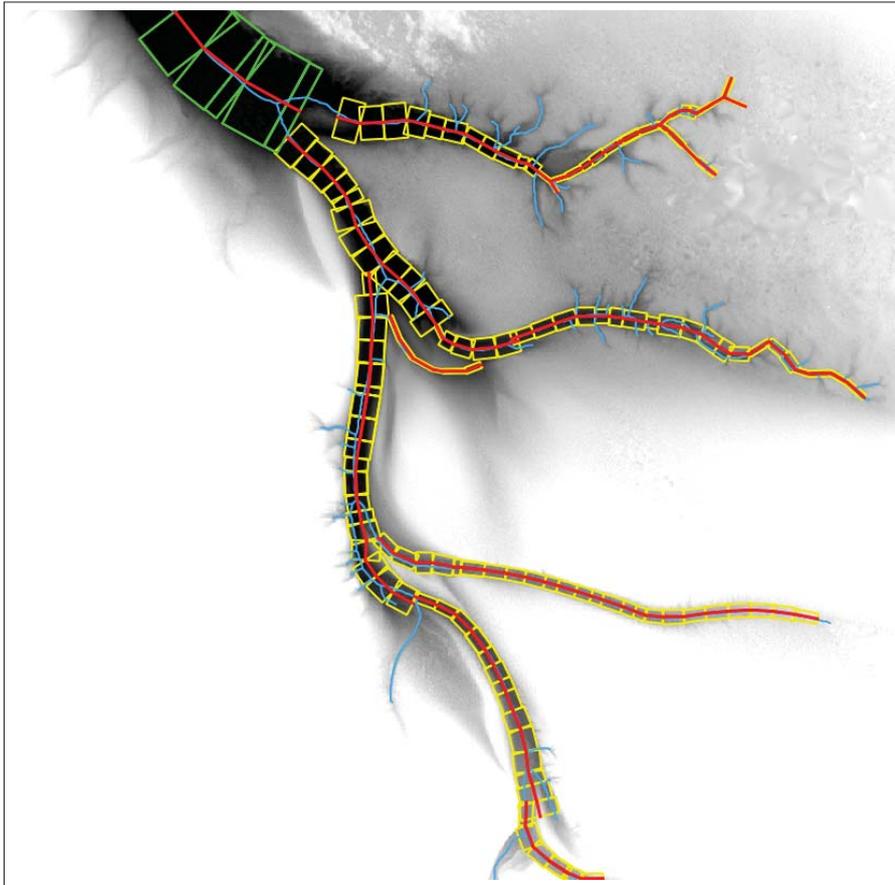
Datensatz	DGM [m]	Parameter	V [%]	K [%]	Q [%]	RMS [px]
Watt	2, 5, 10, 20	$\beta = 0.15$	50.6	78.2	44.3	0.34
Watt (Gebiet 1)	1, 2	$\beta = 0.3$	70.1	96.1	68.9	2.75
	1, 2	$\beta = 0.4$	72.7	94.4	69.7	2.67
Vorarlberg	5, 10	$\beta = 0.04$	61.4	68.4	47.9	1.04
	5, 10	$\beta = 0.05$	64.5	63.1	46.9	1.05
Vorarlberg (Ausschnitt)	5, 10	$\beta = 0.04$	75.4	73.6	59.4	0.94
	5, 10	$\beta = 0.05$	85.9	68.2	61.3	0.95
	1, 5	$\beta = 0.05$	87.7	55.4	51.4	0.98

**Tabelle 6.5.:** Genauigkeitsergebnisse der **pixelweisen** Evaluation.

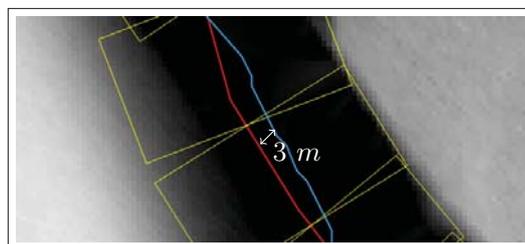
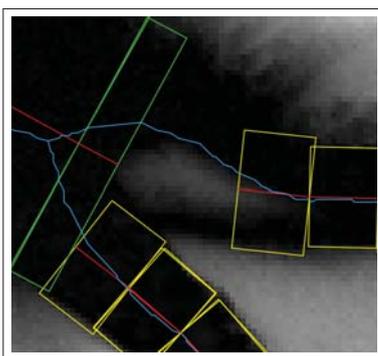
Datensatz	DGM [m]	Parameter	V [%]	K [%]	Q [%]
Watt	2, 5, 10, 20	$\beta = 0.15$	79.7	80.3	66.7
Watt (Gebiet 1)	1, 2	$\beta = 0.3$	80.7	85.8	71.3
	1, 2	$\beta = 0.4$	83.7	82.2	70.9

Gewässernetzen eingesetzt werden kann. Die eingeführten Parameter, insbesondere das Gewicht  $\beta$ , ermöglichen die Anpassung an Gewässerläufe in unterschiedlichen Geländeformen. In den Ergebnissen werden eine Vielzahl der Priele und Flüsse erkannt. Jedoch fehlen einige der kleineren Zuflüsse im Extraktionsergebnis. Eine mögliche Lösung hierfür könnte die Einführung einer weiteren Hierarchiestufe mit angepassten Modellparametern sein. Auch ist es denkbar, die Eingangsdaten in einem Vorverarbeitungsschritt zu klassifizieren und für jede Klasse angepasste Modellparameter zu nutzen. Auf diese Weise ließen sich die fehlenden Flüsse im Stadtbereich möglicherweise auffinden. Als kritisch muss darüber hinaus bewertet werden, dass mehr Flüsse im Extraktionsergebnis ausgegeben werden als in den Referenzdaten vorhanden sind. Insbesondere bei Senken, die in ihrer Ausprägung Flussbetten ähneln, kommt es zu Verwechslungen. Hier zeigt sich, dass eine stärkere Gewichtung des Prioriterms im Vergleich zum Datenterm die Korrektheit der Ergebnisse verbessert, da auf diese Weise dem Modell ein größeres Gewicht gegenüber den Daten beigemessen wird. Jedoch geht dies auf Kosten der Vollständigkeit des Flussnetzes im Extraktionsergebnis.

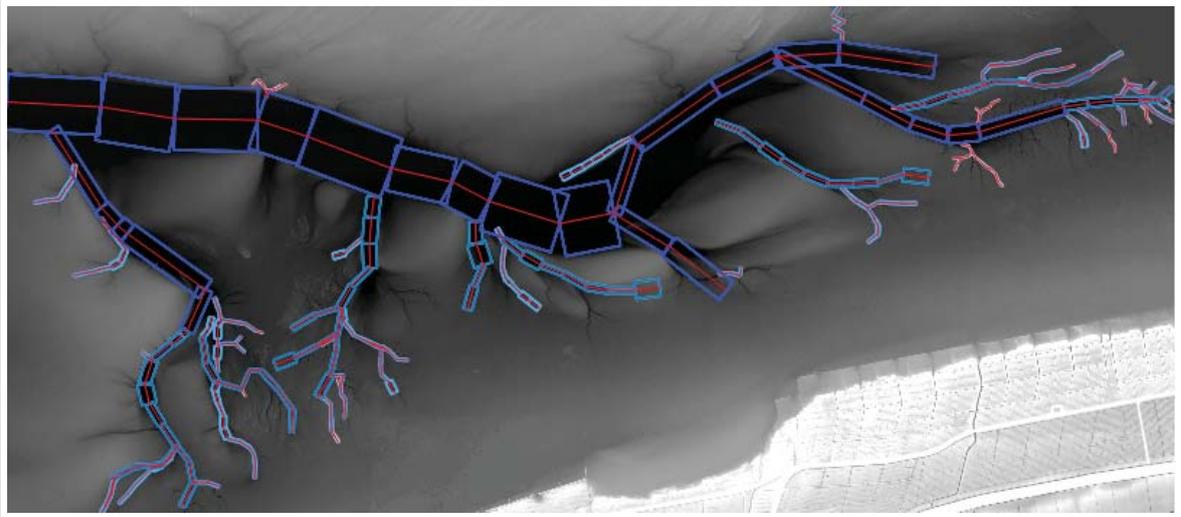
Wird eine hierarchische Extraktion der Gewässernetze durchgeführt, zeigt sich insbesondere bei Priele, dass die Bäume aus den einzelnen Hierarchiestufen nicht miteinander verbunden sind. Auch in anderen Bereichen treten Lücken im Liniennetz des Ergebnisses auf, insbesondere dann, wenn schmale Flüsse mit breiteren zusammenlaufen. Dies kann einerseits mit der Bestrafung durch den Überlappungsterm im Bereich von Kreuzungen erklärt werden. Zum anderen reicht der für kleine Flussläufe gering gewählte Suchradius  $r$  beim Einfügen neuer Kanten für feine Auflösungsstufen nicht aus, um die Verbindung zu ermöglichen. An dieser Stelle ist eine Modellerweiterung in der Form denkbar, dass zum Einfügen von Verbindungen zwischen unterschiedlichen Hierarchiestufen der Nachbarschaftsradius in den Kernen erhöht wird. Auch könnte die Bestrafung von überlappenden Segmenten in diesen Bereichen ausgeschlossen werden.



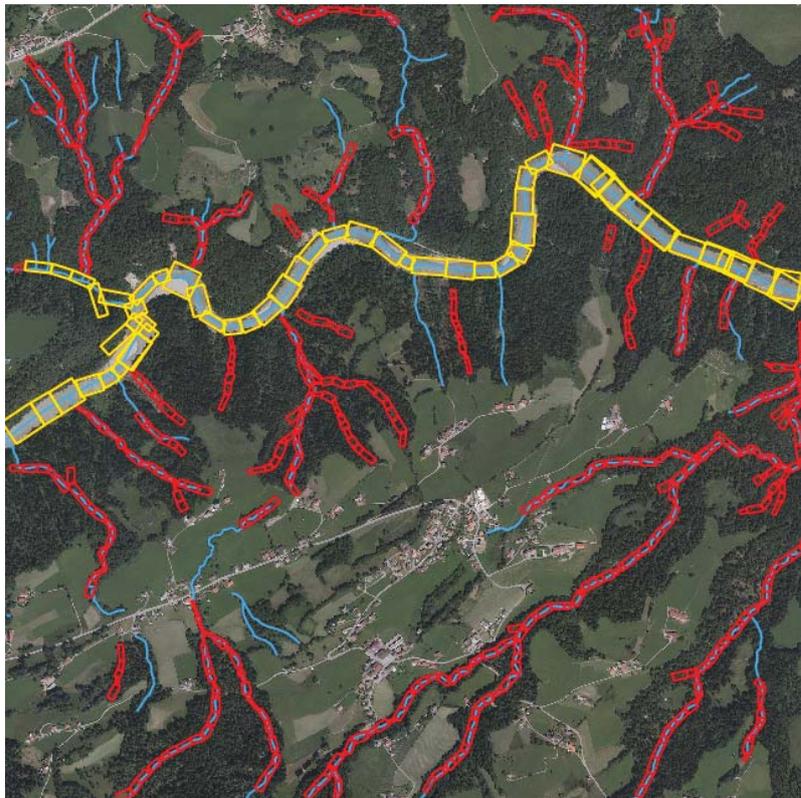
**Abbildung 6.6.:** Ergebnis für *Gebiet 1* des Wattenmeeres mit den extrahierten Kanten (rot) des Graphen sowie deren Segmenten in der ersten (grün) und zweiten (gelb) Hierarchiestufe ( $\beta = 0.04$ ). Die blaue Linie kennzeichnet das Referenzliniennetz.



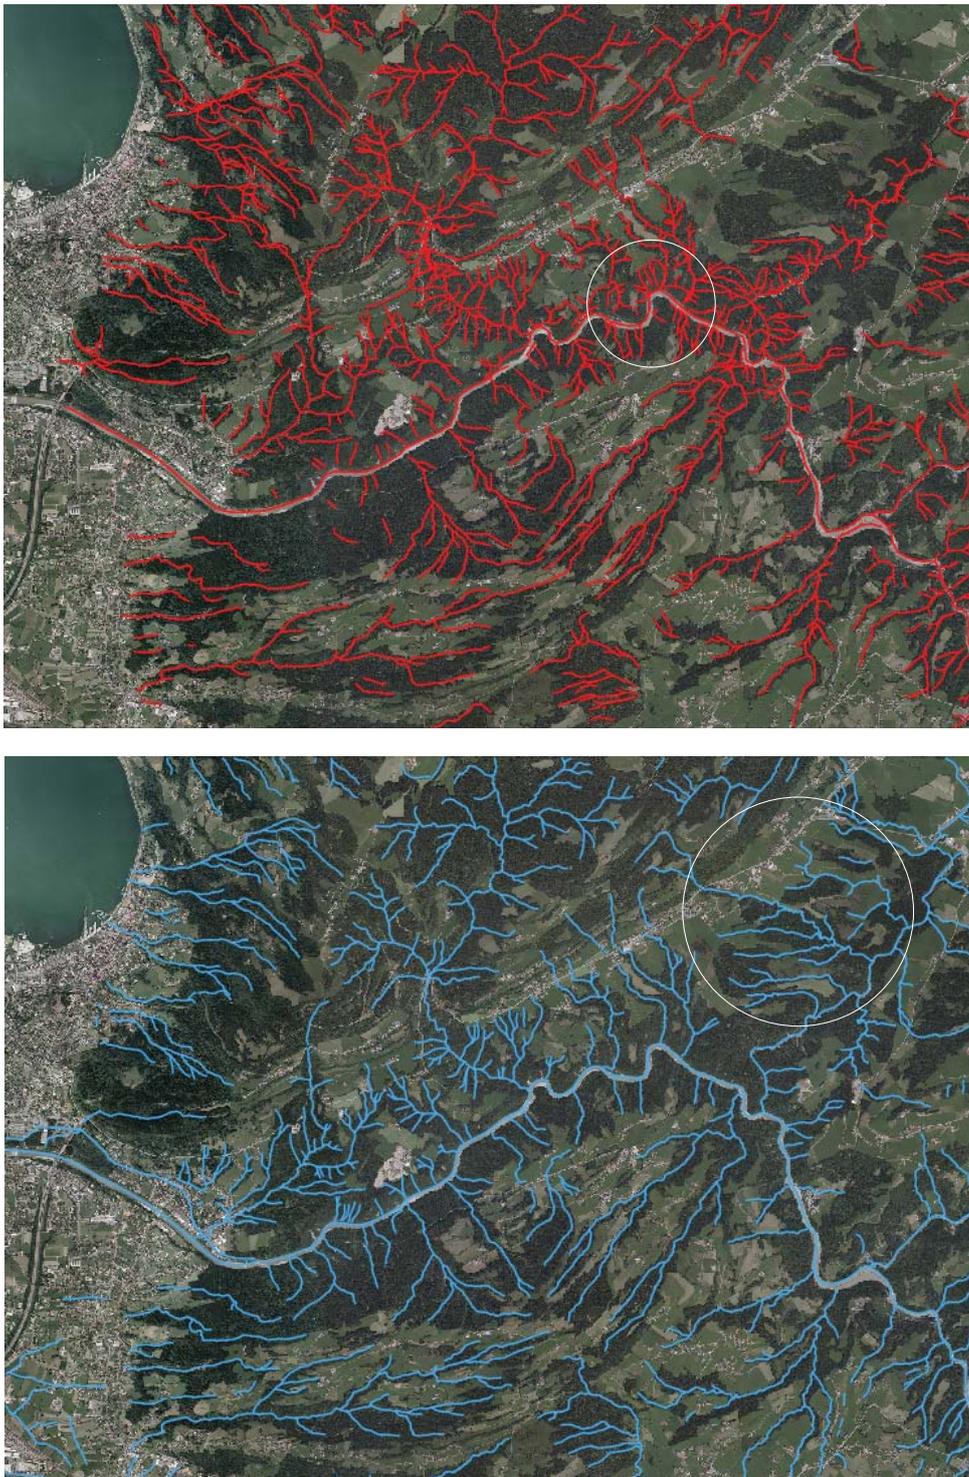
**Abbildung 6.7.:** Abweichungen vom Referenznetz, die im Ergebnis des *Forest Point Process* zu beobachten sind. Links: Im Bereich einer Sandbank wird keine Verbindung des Graphen gefunden. Rechts: Die geometrische Genauigkeit im Prielnetz ist in den Bereichen recht hoch, in denen an mindestens einer Uferseite die Gradienten schwach ausgeprägt sind, wie hier exemplarisch aufgezeigt ist. Während der Höhenanstieg vom Priel zur Landfläche auf der rechten Seite recht stark ausgeprägt ist, ist der Übergang auf der linken Seite flacher. Der Priel wird hier zu breit geschätzt und die Kante im Graph (rot) weicht von der Referenz (blau) ab.



**Abbildung 6.8.:** Ergebnis des *Forest Point Process* für die große Szene des Wattenmeeres. Mit zunehmender Helligkeit des Blautons wurde eine feinere Auflösung der Eingangsdaten in der hierarchischen Extraktion verwendet.



**Abbildung 6.9.:** Ergebnis für den Ausschnitt in Vorarlberg ( $\beta = 0.04$ ). Es sind die extrahierten Segmente des *Forest Point Process* aus der ersten (gelb) und der zweiten Hierarchiestufe (rot) dargestellt. Zudem ist das Referenzliniennetz (blau) gezeigt.



**Abbildung 6.10.:** Gegenüberstellung des Ergebnisses des Liniennetzes aus dem *Forest Point Process* (oben) und der Referenz (unten) für das Testgebiet *Vorarlberg* ( $\beta = 0.04$ ). Der *Forest Point Process* extrahiert dabei in Bereichen mit starken Höhenunterschieden nahe der Bregenzer Ach zu viele Flüsse (z.B. im mit einem Kreis gekennzeichneten Bereich im Ergebnis). Einige kleinere Flüsse werden hingegen nicht erkannt (z.B. im mit einem Kreis gekennzeichneten Bereich in der Referenz).

### 6.2.2. Einfluss der Parameter

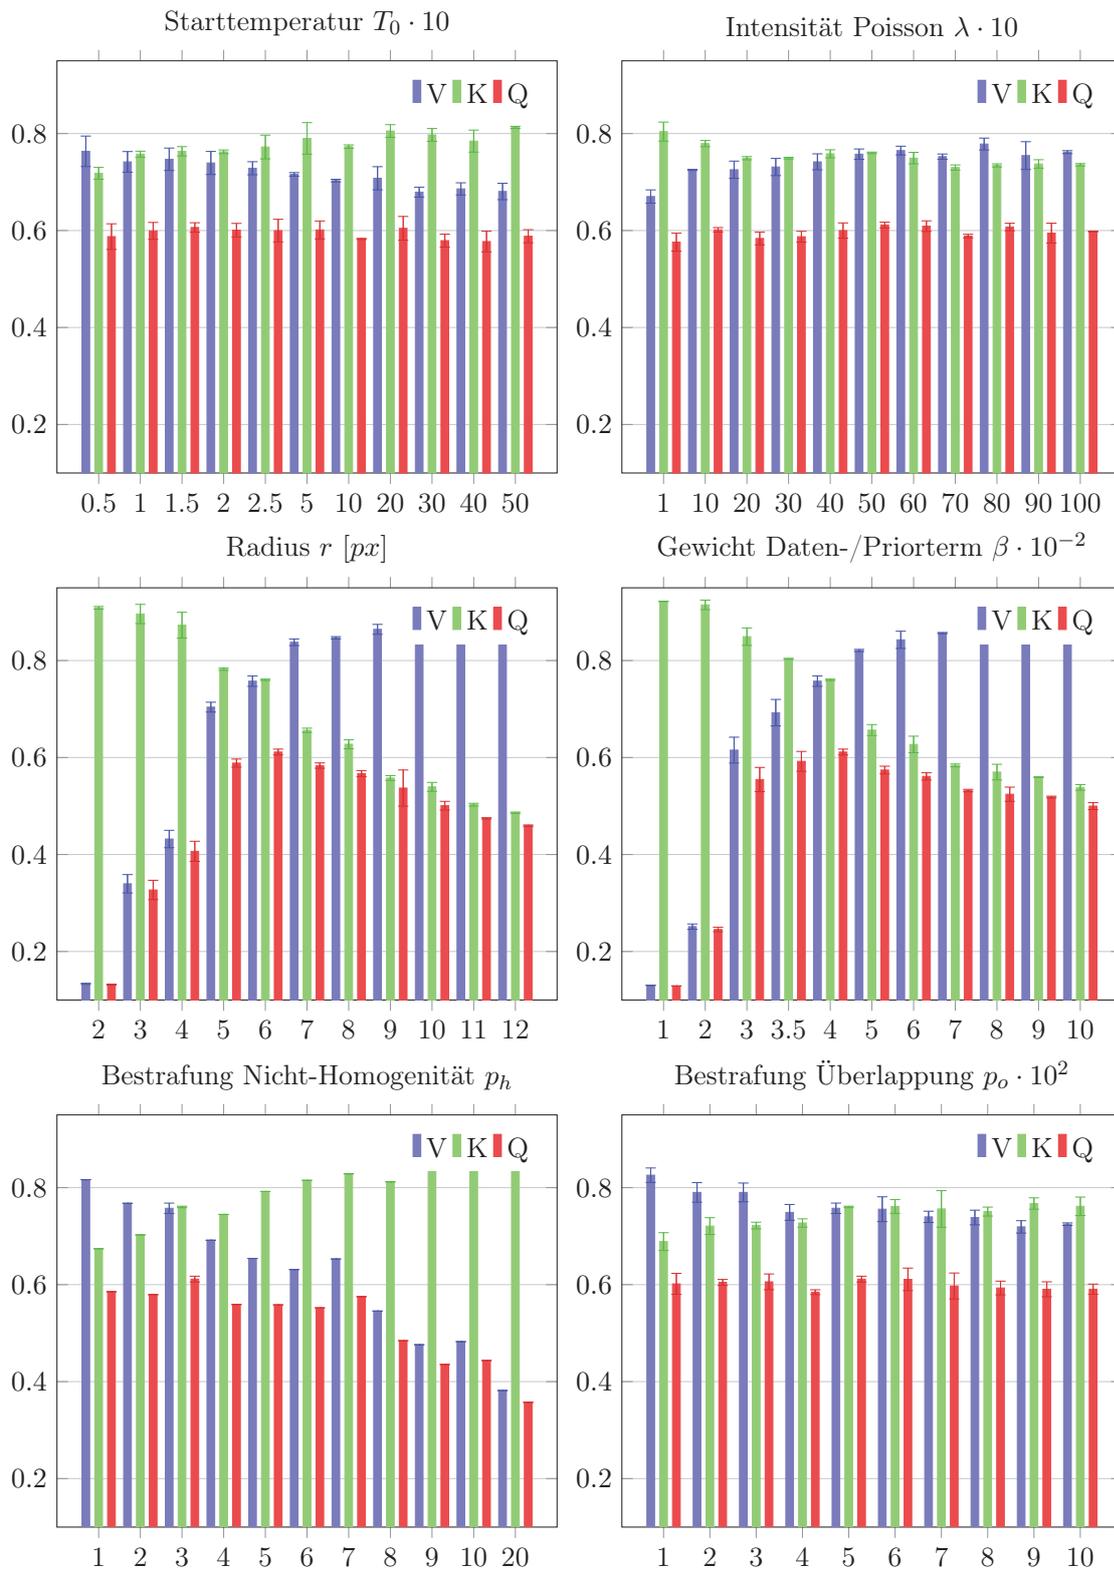
**Experiment:** Im *Forest Point Process* fließen verschiedene Parameter in die Energiefunktion und bei den Änderungen der Graphkonfiguration in das Modell ein. Diese sind vom Nutzer vorzugeben. Welchen Einfluss die gewählten Parametereinstellungen auf das Ergebnis haben, soll am Beispiel des Gebietes *Vorarlberg (Ausschnitt)* im Folgenden aufgezeigt werden. Für das Experiment mit den österreichischen Daten werden die Ergebnisse aus der ersten Hierarchiestufe (10 *m* Auflösung) festgehalten und lediglich die Parameter der zweiten Hierarchiestufe (5 *m* Auflösung) variiert. Sofern Unterschiede im Vergleich zu dem Einfluss der Parameter auf die Ergebnisse in Wattgebieten auftreten, sind diese im Text angeführt. Die in Tabelle 5.4 angeführten Parameter werden dabei als Standardeinstellung gewählt. Einer der Parameter wird dann variiert, während die anderen Parameter beibehalten werden. Um den Einfluss des Ziehens der Zufallszahlen zu berücksichtigen, wird das Experiment zudem wiederholt. Da der geringe Einfluss auf die Ergebnisse durch das Ziehen der Zufallszahlen bereits in Abschnitt 6.1.3 am Beispiel von 100 Wiederholungen gezeigt werden konnte, wird hier nur eine vergleichsweise geringe Anzahl von drei Wiederholungen gewählt. Die Ergebnisse werden anhand der Qualitätsmaße Vollständigkeit, Korrektheit und Qualität bewertet.

**Ergebnis:** Die Qualitätsmaße der Ergebnisse bei den unterschiedlichen Parametereinstellungen geben die Balkendiagramme in den Abbildungen 6.11 und 6.13 wieder. Die Ergebnisse eines jeden Parameters werden im Folgenden kurz diskutiert.

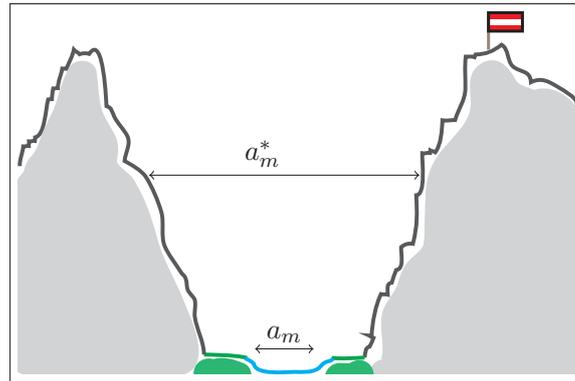
- Eine Variation der Starttemperatur  $T_0$  im *Simulated Annealing* wirkt sich nur geringfügig auf das Ergebnis aus. Die Abkühlung wird im Modell stets auf die Temperatur  $T_{t_{max}} = 0$  vorgenommen und der Abkühlungskoeffizient entsprechend der konstant gewählten Iterationsanzahl  $t_{max}$  angepasst. Der geringe Einfluss auf die Qualitätsmaße verdeutlicht, dass die Iterationsanzahl ausreichend hoch gewählt wurde.
- Der Einfluss der Intensität  $\lambda$  im Poisson-Punktprozess ist ebenfalls sehr gering. Dieser Parameter entspricht dem Erwartungswert für die Objektanzahl und fließt bei der Berechnung der Green-Ratio im *Birth-and-Death*-Ereignis sowie bei der Änderung *Split-and-Merge* in das Modell ein. Der Anteil scheint dabei im Vergleich zu den weiteren Größen in der Green-Ratio – insbesondere bezüglich der Energie  $U$  – zu gering zu sein, um das Ergebnis signifikant bezüglich der Genauigkeitsmaße zu ändern. Jedoch zeigt die Auswertung der Energie  $U$ , dass diese mit zunehmendem Wert für  $\lambda$  im Endergebnis geringer wird. Hier erweist sich ein höherer Wert für die Intensität somit als günstig. Des Weiteren lässt sich eine Zunahme der Objektanzahl bei steigendem Wert für die Intensität beobachten. So sind beispielsweise für  $\lambda = 100$  im Graph 636 Knoten enthalten, während deren Anzahl 760 für  $\lambda = 800$  beträgt.
- Die Variation des Suchradius  $r$  bei den Änderungen der Konfiguration im *Birth*-Kernel sowie im *Split-and-Merge*-Kernel wirkt sich recht stark auf die Qualitätsmaße des Ergebnisses aus. Dies kann damit erklärt werden, dass bei Wahl eines zu kleinen Wertes lediglich eine geringe Anzahl an Knoten in der Nachbarschaft gefunden und nur wenige Kanten hinzugefügt werden. Gleichzeitig ist die Summe der Gradienten im Datenterm für kurze Segmente geringer als für längere Segmente und verringert den Wert der Energiefunktion daher weniger stark. Ist  $r$  hingegen zu groß gewählt,

werden einige Knoten über lange Distanzen hinweg miteinander verbunden. Insbesondere im Bereich von stark mäandrierenden Flüssen werden die Gewässer durch gerade Liniensegmenten dann nicht mehr korrekt wiedergegeben, was zu einer verringerten Korrektheit führt.

- Der Parameter  $\beta$  reguliert die Gewichtung zwischen Daten- und Priorterm. Insgesamt zeigt sich, dass eine Erhöhung dieses Parameters, also eine stärkere Gewichtung des Datenterms, zu höheren Vollständigkeitsraten führt. Gleichzeitig verringert sich die Korrektheit, da auch in Bereichen wie Senken im DGM Flüsse vorgeschlagen werden. Je nach Aufgabenstellung kann dieser Parameter gewählt werden: Ist in erster Linie eine hohe Vollständigkeit des Netzes von Belang, sollte der Datenterm mit hohem Gewicht im Samplingverfahren berücksichtigt werden. Ist hingegen die Korrektheit der Ergebnisse von Bedeutung, kann dem mit einer stärkeren Berücksichtigung des Modellwissens im Priorterm Rechnung getragen werden, wie auch in Abschnitt 6.2.1 deutlich wurde. Zudem zeigen sich Abhängigkeiten von der betrachteten Geländeform. In Wattgebieten, in denen die Gradienten an den Prielufern geringer ausfallen als im bergigen Vorarlberg und der Datenterm insgesamt einen geringeren Betrag annimmt, ist  $\beta$  um mindestens den Faktor drei höher gewählt als für die Daten aus Österreich.
- Für den Gewichtungsfaktor  $p_h$  des Homogenitätskriteriums  $U_h$  im Datenterm sind die Auswirkungen in den Qualitätsmaßen vergleichsweise gering. Dennoch erweist sich der Term insbesondere bei Flussläufen zwischen Bergen als hilfreich. Zu breite Flüsse, wie sie bei ausschließlicher Berücksichtigung hoher Gradienten an den Ufern im Datenterm angenommen werden können, lassen sich dadurch verhindern (siehe Abbildung 6.12). Für die Daten aus den Wattgebieten ist dieser Term hingegen weniger relevant und kann geringer gewichtet werden.
- Die Unterschiede in den Genauigkeiten bei Variation des Bestrafungsfaktors  $p_o$  der Überlappungsflächen sind gering. Jedoch ist die Anpassung dieses Parameters – wie in Abschnitt 6.1.2 diskutiert – essentiell, um topologisch korrekte Gewässernetze zu extrahieren, was durch die gewählten Qualitätskriterien nicht wiedergegeben wird. Unterschiede in den Ergebnissen sind zudem in der Objektanzahl zu erkennen. Während bei einem Gewicht von  $p_o = 100$  im Endergebnis 1709 Knoten enthalten sind, ist die Anzahl mit 649 bei  $p_o = 1000$  um den Faktor 2.6 kleiner.
- Je größer der Bestrafungsfaktor  $p_c$  für nicht-verbundene Bäume gewählt wird, umso weniger Flüsse werden gefunden. Dies kann damit begründet werden, dass bei hohen Werten für  $p_c$  das Einfügen von neuen Bäumen nicht zugelassen wird, sondern nur Verbindungen zu bereits bestehenden Bäumen ermöglicht werden. Die gewählte Anzahl an Iterationen erscheint in diesen Fällen nicht ausreichend hoch zu sein, um weite Teile des Netzes zu extrahieren. Folglich sinkt die Vollständigkeitsrate. Jedoch helfen große Werte für diesen Parameter, um hohe Korrektheitsraten zu erzielen, da sich mit Hilfe dieses Terms das Annehmen einzelner Senken – die ähnliche Eigenschaften bezüglich ihrer Gradienten wie Flussläufe haben, jedoch nicht mit dem Netz verbunden sind – verhindern lässt. Eine geeignete Größe für diesen Faktor kann in Abhängigkeit der weiteren Gewichtungsfaktoren im Priorterm gefunden werden. Experimentelle Untersuchungen haben gezeigt, dass gute Ergebnisse erzielt werden können, sofern  $p_c \leq 0.5 \cdot p_o$  und  $p_c \geq 2 \cdot p_f$  gewählt ist.

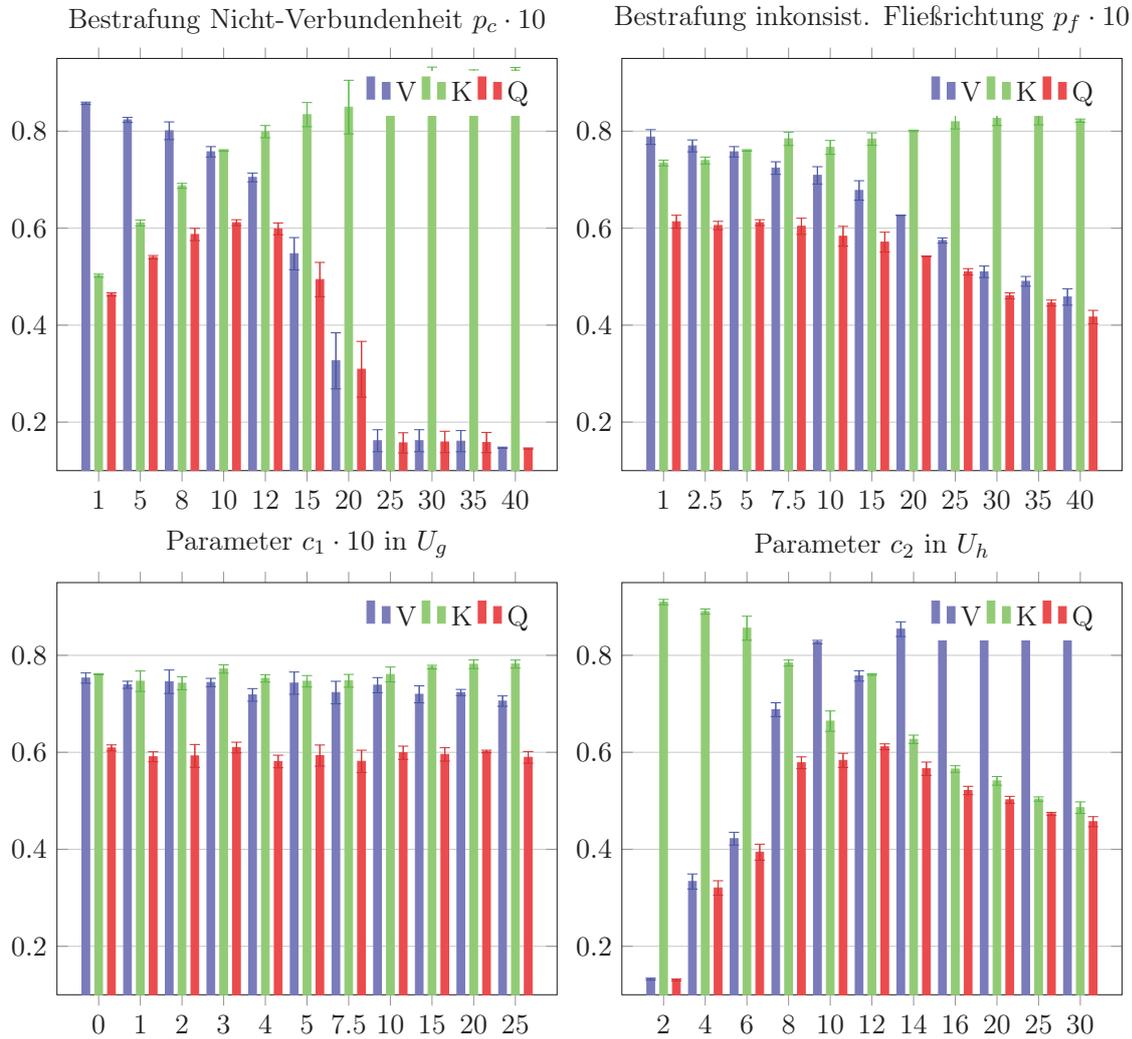


**Abbildung 6.11.:** Einfluss der Parameter auf das Ergebnis, bewertet anhand der Qualitätsmaße Vollständigkeit  $V$ , Korrektheit  $K$  und Qualität  $Q$ . Die Streuung der Ergebnisse bei mehrmaliger Wiederholung wird in Form einer Standardabweichung gegeben.



**Abbildung 6.12.:** Das Homogenitätskriterium  $U_h$  bewirkt, dass Segmente im Samplingprozess angenommen werden, deren Ränder  $a_m$  mit den Ufern des Flusses übereinstimmen. Eine potentielle Kante  $a_m^*$ , die ebenfalls zu einer Reduktion der Energie durch hohe Gradientenbeträge führt, wird auf Grund der Bestrafung durch  $U_h$  mit hoher Wahrscheinlichkeit verworfen.

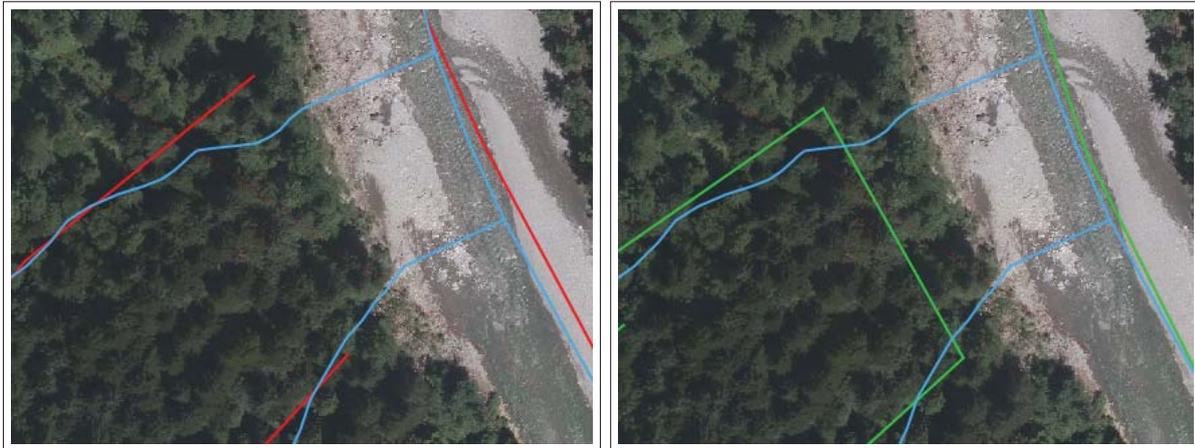
- Der Bestrafungsfaktor  $p_f$  der Inkonsistenten bezüglich der Fließrichtung im Priorterm  $U_f$  zeigt einen ähnlichen Einfluss wie  $p_c$  auf das Ergebnis. Eine Erhöhung dieses Wertes führt zu höheren Korrektheits-, aber geringeren Vollständigkeitsraten. Sowohl für die Szene des Wattenmeeres als auch des Gebietes in Vorarlberg lassen sich Genauigkeitssteigerungen erkennen, sobald das physikalische Wissen in Form von  $U_f$  im Modell integriert ist (siehe Tabelle 6.6). Für die Daten aus dem Watt können dabei um 2.4 % bzw. 1.7 % höhere Vollständigkeits- bzw. Korrektheitsraten sowie eine Verbesserung der Qualität um 3.0 % erzielt werden. In dem Gebiet Vorarlberg ist ebenfalls ein Anstieg der Korrektheit zu beobachten, hier um 3.4 % im Vergleich zu Experimenten, in denen der Term  $U_f$  nicht berücksichtigt ist ( $p_f = 0$ ). Jedoch werden weniger Flüsse gefunden und die Vollständigkeit verschlechtert sich geringfügig um 0.5 %. Insgesamt nimmt die Qualität um 2.6 % zu. Der Priorterm hat den Nutzen, dass in einigen Bereichen fehlerhafte Konfigurationen im Graphen verhindert werden. In Abbildung 6.14 wird die Verbindung zweier Flüsse mit einem größeren Fluss sowohl mit als auch ohne den Term  $U_f$  nicht gefunden. Jedoch wird bei Vernachlässigung von  $U_f$  stattdessen eine fehlerhafte Verbindung zwischen den beiden kleinen Flüssen vorgeschlagen, die bei Berücksichtigung des Terms bezüglich der Fließrichtung verhindert wird.
- Das Variieren des Parameters  $c_1$  im Datenterm in Gleichung (4.3) wirkt sich nur minimal auf die Ergebnisse in Vorarlberg aus. Jedoch erweist sich die Anpassung dieses Parameters für die Daten im Wattenmeer als hilfreich. Wird über diesen Parameter eine minimale Summe der Gradientenbeträge an den Kanten der Liniensegmente eingefordert, kann verhindert werden, dass Segmente auf den horizontalen Landflächen (wo die Summe der Gradientenbeträge nahe Null liegt) vorgeschlagen werden, wie in Abbildung 6.15 veranschaulicht ist.
- Werden über die zweite Konstante  $c_2$  im Homogenitätsterm  $U_h$  in Gleichung 4.4 große Schwankungen in Querprofilen zugelassen ( $c_2$  hoch gesetzt), sinkt die Korrektheit der Ergebnisse. Gleichzeitig werden mehr Flüsse des Gewässernetzes gefunden.



**Abbildung 6.13.:** Einfluss der Parameter auf das Ergebnis, bewertet anhand der Qualitätsmaße Vollständigkeit  $V$ , Korrektheit  $K$  und Qualität  $Q$ . Die Streuung der Ergebnisse bei mehrmaliger Wiederholung wird in Form einer Standardabweichung gegeben.

**Tabelle 6.6.:** Vergleich der Genauigkeitsergebnisse (Vollständigkeit  $V$ , Korrektheit  $K$ , Qualität  $Q$ , geometrische Genauigkeit  $RMS$ ) für den *Forest Point Process*, wenn der Bestrafungsterm bezüglich inkonsistenter Fließrichtungen  $U_f$  berücksichtigt bzw. vernachlässigt wird.

Datensatz	DGM [m]	Methode	V [%]	K [%]	Q [%]	RMS [px]
Watt (Gebiet 1)	1, 2	mit $U_f$	72.7	94.4	69.7	2.67
		ohne $U_f$	70.3	92.7	66.6	2.56
Vorarlberg (Ausschnitt)	5, 10	mit $U_f$	85.9	68.2	61.3	0.95
		ohne $U_f$	86.4	64.8	58.7	0.93



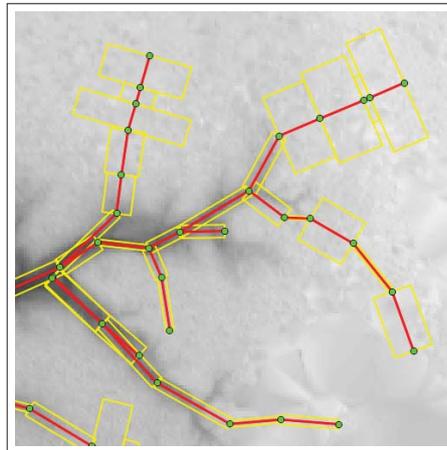
**Abbildung 6.14.:** Referenznetz (blau) und Ergebnisse des *Forest Point Process*, sofern das Fließrichtungskriterium  $U_f$  im Priorterm berücksichtigt ist (links) bzw. vernachlässigt wird (rechts). Zwar sind in beiden Fällen die kleinen parallel verlaufenden Flüsse nicht mit dem größeren Fluss verbunden, jedoch kann unter Verwendung von  $U_f$  eine fehlerhafte Verbindung quer dazu verhindert werden.

**Diskussion:** Die Experimente zeigen, dass sich das Variieren der Parameter unterschiedlich auf die Ergebnisse auswirkt. Die Streuung durch das Generieren der Zufallszahlen, wie durch die Fehlerbalken symbolisiert, kann dabei als gering eingestuft werden. Durch die Parameter kann das Modell an unterschiedliche Szenen angepasst werden. Auf einige der Parameter reagiert das Modell dabei recht sensibel. Hier bedarf es gewisser Erfahrung des Nutzers, um sinnvolle Größenordnungen für die Parameter zu finden. Als vorteilhaft kann herausgestellt werden, dass sich in den Experimenten ähnliche Parametereinstellungen für dieselben Arten von Gebieten als geeignet erwiesen haben, d.h. einmal bestimmte Parameter für Wattgebiete können auf andere Bereiche im Watt übertragen werden (siehe Tabelle 5.4). Grundsätzlich kann jedoch das erforderliche Expertenwissen sowie die große Anzahl an zu setzenden Parametern als kritisch betrachtet werden. Letzteres trifft jedoch auf die meisten Sampling-Verfahren in der Literatur zu. Das Erzeugen von Trainingsdaten und das Lernen dieser Parameter erscheint in diesem Zusammenhang attraktiv. Ein solches Vorgehen wird beispielsweise in den Verfahren von Börcs & Benedek [2015], Benedek & Martorella [2014] und Chai et al. [2013] gewählt.

Die Berücksichtigung von physikalischem Wissen über die Fließrichtung des Gewässernetzes im Priorterm  $U_f$  kann über dessen Gewicht  $p_f$  gesteuert werden. Hier zeigen die Experimente, dass für beide Testgebiete die Korrektheit der Ergebnisse durch Berücksichtigung dieses Wissens erhöht wird. Für das österreichische Testgebiet verschlechtert sich dabei jedoch die Vollständigkeit des extrahierten Flussnetzes geringfügig. Als Vorteil bleibt dennoch bestehen, dass ein physikalisch korrektes Modell des Gewässernetzes vorliegt.

### 6.2.3. Vergleich mit Standardverfahren

**Experiment:** In praktischen Anwendungen erfolgt die Extraktion von Gewässernetzen häufig mit den in Abschnitt 2.1.1 angeführten *Flow Routing*-Algorithmen (z.B. O’Callaghan & Mark [1984]; Lea [1992]; Quinn et al. [1991]; Freeman [1991]). Es handelt sich hierbei um lokale Verfahren, welche auf Grundlage lokaler Geländeneigungen den Lauf des Wassers bestimmen. Die Ergebnisse eines solchen



**Abbildung 6.15.:** In Wattgebieten werden viele Kanten fehlerhaft auf dem horizontalen Land eingefügt, sofern keine Mindestgröße für die Gradientensumme in Form der Konstante  $c_1$  im Datenterm  $U_g$  berücksichtigt ist.

Standardverfahrens sind im Folgenden denen des *Forest Point Process* gegenübergestellt. Als Eingangsdaten wurden *Gebiet 1* aus dem Wattgebiet sowie der Ausschnitt aus Vorarlberg gewählt. Für das *Flow Routing*-Verfahren wird der Ansatz *Multiple Flow Direction* verwendet [Holmgren, 1994], der in GRASS-GIS implementiert ist (*r.stream.extract* [Jasiewicz & Metz, 2011]). Hierin sind zwei Parameter vom Nutzer vorzugeben: (1) eine minimale Segmentlänge, welche die minimale Länge zusammenhängender Pixel beschreibt, ab der Pixel als Fluss ausgegeben werden, (2) die minimale Fläche des Wassereinzugsgebiets  $C_a$ , die die minimale Fläche angibt, von der ein Pixel mit Wasser gespeist werden muss, damit es als zum Netz zugehörig erkannt wird. Im Folgenden wird die minimale Segmentlänge auf  $100\text{ m}$  gesetzt, für die minimale Fläche des Wassereinzugsgebiets  $C_a$  werden unterschiedliche Größen getestet:  $C_a = 7500\text{ m}^2$ ,  $C_a = 12500\text{ m}^2$ ,  $C_a = 25000\text{ m}^2$ . Die Einstellungen entsprechen den Werten von Vetter & Mandlbürger [2014], die dasselbe Verfahren für DGMs desselben Gebietes in Vorarlberg anwenden.

**Ergebnis:** Ein quantitativer und ein visueller Vergleich der Ergebnisse des *Flow-Routing*-Verfahrens (FR) mit dem *Forest Point Process* (FPP) ist in Tabelle 6.7 und in Abbildung 6.16 gegeben. Für den *Flow Routing*-Ansatz lässt sich beobachten, dass mit zunehmender Größe für den Parameter  $C_a$  die Anzahl der Pixel abnimmt, die als Priernetz erkannt werden. Die extrahierten Priele sind dann an den Enden kürzer (siehe Abbildung 6.16). Dies geht einher mit einer steigenden Korrektheitsrate bei einer sinkenden Vollständigkeit des Priernetzes. Im Gegensatz zum *Forest Point Process* werden die Mittelachsen der Priele nicht durch geradlinige Kanten repräsentiert. Vielmehr zeigt sich ein stark gezackter Verlauf, der zu teilweise großen Abweichungen bezüglich des Referenznetzes führt. Dies schlägt sich in einer deutlich geringeren geometrischen Genauigkeit von  $RMS_{FR} = 4.35\text{ px}$  im Vergleich zu  $RMS_{FPP} = 2.67\text{ px}$  bei einer Pixelgröße von  $1\text{ m}$  nieder. Auch die übrigen Qualitätsmaße weisen bessere Werte für den *Forest Point Process* auf. Während die Vollständigkeit in einer ähnlichen Größenordnung liegt, kann mit  $K_{FPP} = 94.4\%$  im Vergleich zu  $K_{FR} = 75.9\%$  eine signifikant höhere Korrektheit erzielt werden. Die Qualität ist für alle Ergebnisse um  $16 - 20\%$  höher. Als Vorteil des *Flow-Routing*-Verfahrens kann wiederum herausgestellt werden, dass keine Lücken im Ergebnis

**Tabelle 6.7.:** Genauigkeitsergebnisse (Vollständigkeit  $V$ , Korrektheit  $K$ , Qualität  $Q$ , geometrische Genauigkeit  $RMS$ ) des *Forest Point Process* ( $FPP$ ) und des *Flow Routing*-Ansatzes ( $FR$ ) bei variierenden Parametereinstellungen für das Wassereinzugsgebiet  $C_a$ .

Datensatz	DGM [m]	Methode	V [%]	K [%]	Q [%]	RMS [px]
Wattenmeer (Gebiet 1)	1, 2	$FPP$	72.7	94.4	69.7	2.67
		$FR, C_a = 7500$	72.0	61.6	49.7	4.35
		$FR, C_a = 12500$	68.7	71.3	53.8	4.39
		$FR, C_a = 25000$	60.3	75.9	50.6	4.52
Vorarlberg (Ausschnitt)	5, 10	$FPP$	85.9	68.2	61.3	0.95
		$FR, C_a = 7500$	77.7	64.8	54.7	1.01
		$FR, C_a = 12500$	68.5	74.9	55.8	1.01
		$FR, C_a = 25000$	58.8	76.6	49.8	1.07

auftreten. Nicht in allen Fällen ist diese Verbindung jedoch korrekt. In einem rauen Geländeabschnitt des Watts wird der mit einem blauen Pfeil in Abbildung 6.16 gekennzeichnete Priel im Ergebnis des *Flow Routing*-Verfahrens fälschlicherweise erzeugt und mit dem übrigen Netz verbunden.

Etwas geringer ist der Unterschied der Qualitätsmaße für den Datensatz aus Vorarlberg. Jedoch können auch hier mit dem *Forest Point Process* bessere Ergebnisse hinsichtlich der gewählten Qualitätsmaße erzielt werden. So ist die geometrische Genauigkeit der Mittelachsen des Flussnetzes mit  $RMS_{FPP} = 0.95 \text{ px}$  gegenüber  $RMS_{FR} = 1.01 \text{ px}$  geringfügig höher. Ein Anstieg der Qualität  $Q$  lässt sich im Bereich von 6–12 % für den *Forest Point Process* im Vergleich zum *Flow Routing*-Ansatz erzielen. Im *Flow Routing*-Ansatz können fehlende Flüsse an den Rändern der Szene damit erklärt werden, dass das Wassereinzugsgebiet im *Flow Routing*-Ansatz außerhalb der Szene liegt. Bezüglich der Verbundenheit weist der *Flow Routing*-Ansatz erneut einen Vorteil auf, Lücken sind hierin nicht zu beobachten. Dies ist selbst in den Bereichen der Szene nicht der Fall, in denen der oberirdische Verlauf des Flussnetzes unterbrochen ist. Im Beispiel in Abbildung 6.17 verläuft das Gewässernetz in Rohren unterhalb eines Fußballplatzes. Das Ergebnis des *Forest Point Process* hat an dieser Stelle eine Lücke im Liniennetz (siehe Abbildung 6.17) bzw. kann diese Lücke bei ausreichend hohem Suchradius  $r$  durch ein geradliniges Liniensegment geschlossen werden. Im *Flow Routing*-Ansatz wird hingegen ein alternativer Verlauf für das Wasser entsprechend der Neigung im Gelände bestimmt.

**Diskussion:** Im *Forest Point Process* werden die Gewässernetze durch geradlinige Liniensegmente repräsentiert. Im Gegensatz dazu wird das Gewässer im *Flow Routing*-Algorithmus lokal auf Grundlage der Geländeneigungen von Pixel zu Pixel ausgebreitet. Hierbei ergibt sich ein gezackter Verlauf des Gewässernetzes, für den eine Nachbearbeitung in Form einer Glättung für zukünftige Analysen denkbar ist. Der Vergleich der Ergebnisse beider Verfahren zeigt, dass das *Flow Routing*-Verfahren hinsichtlich der Verbundenheit des Netzes dem *Forest Point Process* überlegen ist. Letzterer weist in den Bereichen, in denen ein kleiner Fluss in einen größeren mündet, Lücken auf. Lösungsansätze hierfür wurden bereits in Abschnitt 6.1.2 aufgezeigt. Hinsichtlich der Genauigkeitsmaße der Linienevaluation können jedoch mit dem *Forest Point Process* deutlich bessere Ergebnisse erzielt werden. Dies ist sowohl für Flussnetze in bergigem Gelände als auch für Prielnetze in horizontalem Gelände zu beobachten. Ein stärkerer Genauigkeitsanstieg kann dabei für die Prielnetze erzielt werden.



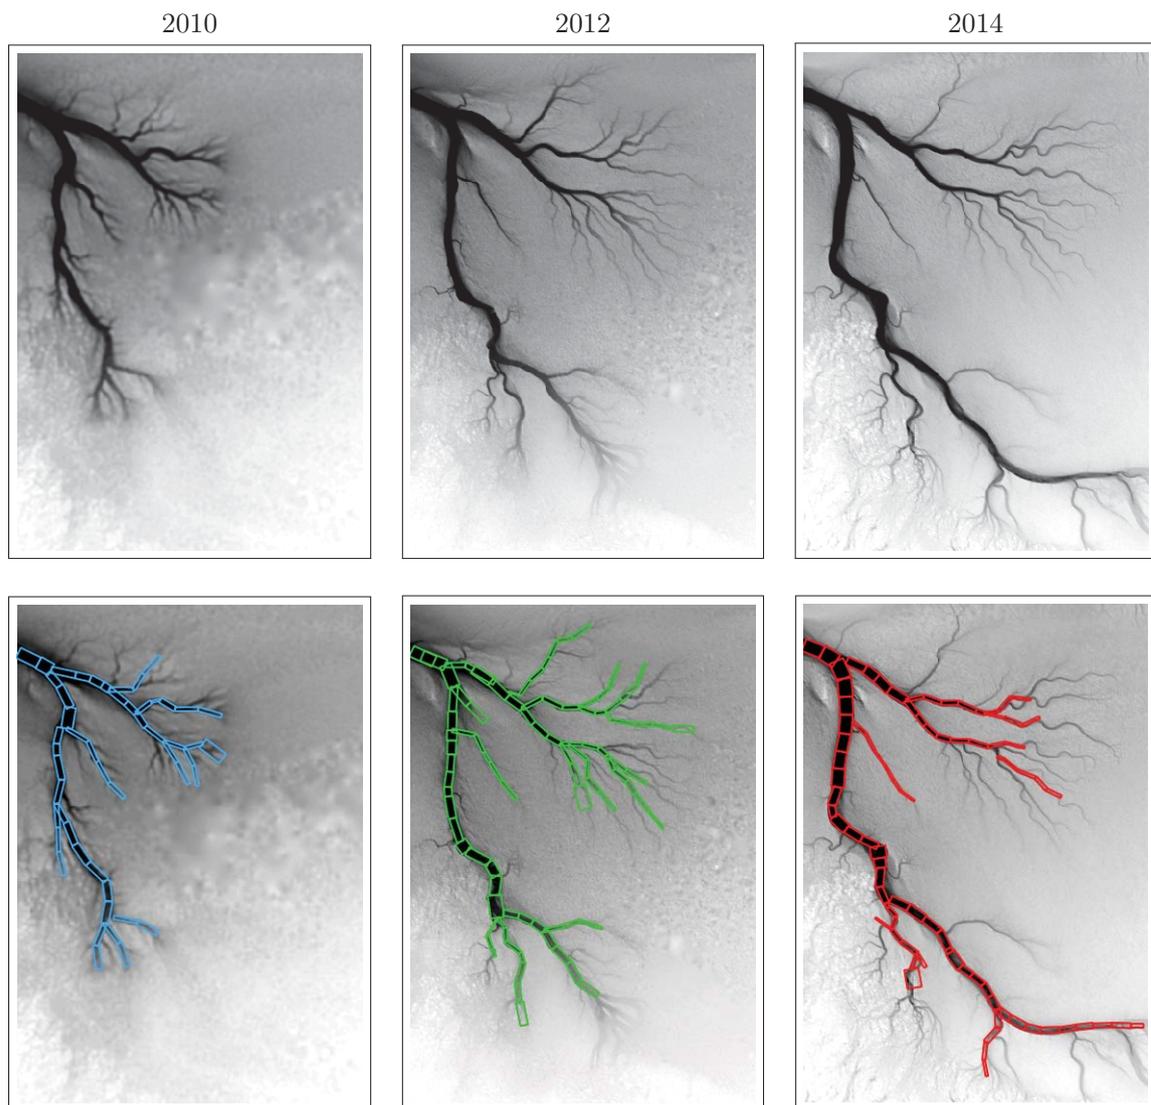


**Abbildung 6.17.:** Das Gewässernetz (blau) verläuft im Bereich eines Fußballplatzes unterirdisch in Rohren. Der *Flow Routing*-Ansatz (grün) bestimmt dann einen alternativen Verlauf des Wassers auf Grundlage der Geländeneigung im DGM. Im Ergebnis des *Forest Point Process* (rot) ist in diesem Bereich das Gewässernetz unterbrochen.

#### 6.2.4. Anwendung für Zeitreihen

**Experiment:** Prielnetze in Wattbereichen weisen eine große zeitliche Variabilität auf. Bedingt durch verschiedene Einflüsse wie Gezeiten, Wind und Sturmfluten kommt es zu einer Verlagerung der Priele. Zudem ist zu beobachten, dass einzelne Priele neu entstehen und andere versanden. Abbildung 6.18 zeigt die Szene *Gebiet 2* im Watt zu drei Zeitpunkten: 2010, 2012, 2014. Veränderungen im Prielnetz lassen sich in den Zeitspannen von jeweils zwei Jahren im DGM deutlich erkennen. Für die Szene wird die Extraktion des Prielnetzes zwei Mal durchgeführt. Zunächst wird der *Forest Point Process* für jede Szene separat angewandt, die Anzahl an Iterationen beträgt dabei  $t_{max} = 2 \cdot 10^6$ . In einem zweiten Experiment wird dann das Ergebnis der vorherigen Epochen als Startkonfiguration im Punktprozess eingesetzt und das Sampling mit denselben Parametereinstellungen erneut durchgeführt. Hieran soll überprüft werden, ob die Konvergenz zum Energieminimum beschleunigt werden kann, sofern eine geeignete Startkonfiguration in der Optimierung eingesetzt ist. Zudem kann hiermit eine mögliche Anwendung des Verfahrens aufgezeigt werden, die in der Praxis genutzt werden könnte, um beispielsweise die Länge des Prielnetzes zu unterschiedlichen Zeitpunkten zu vergleichen.

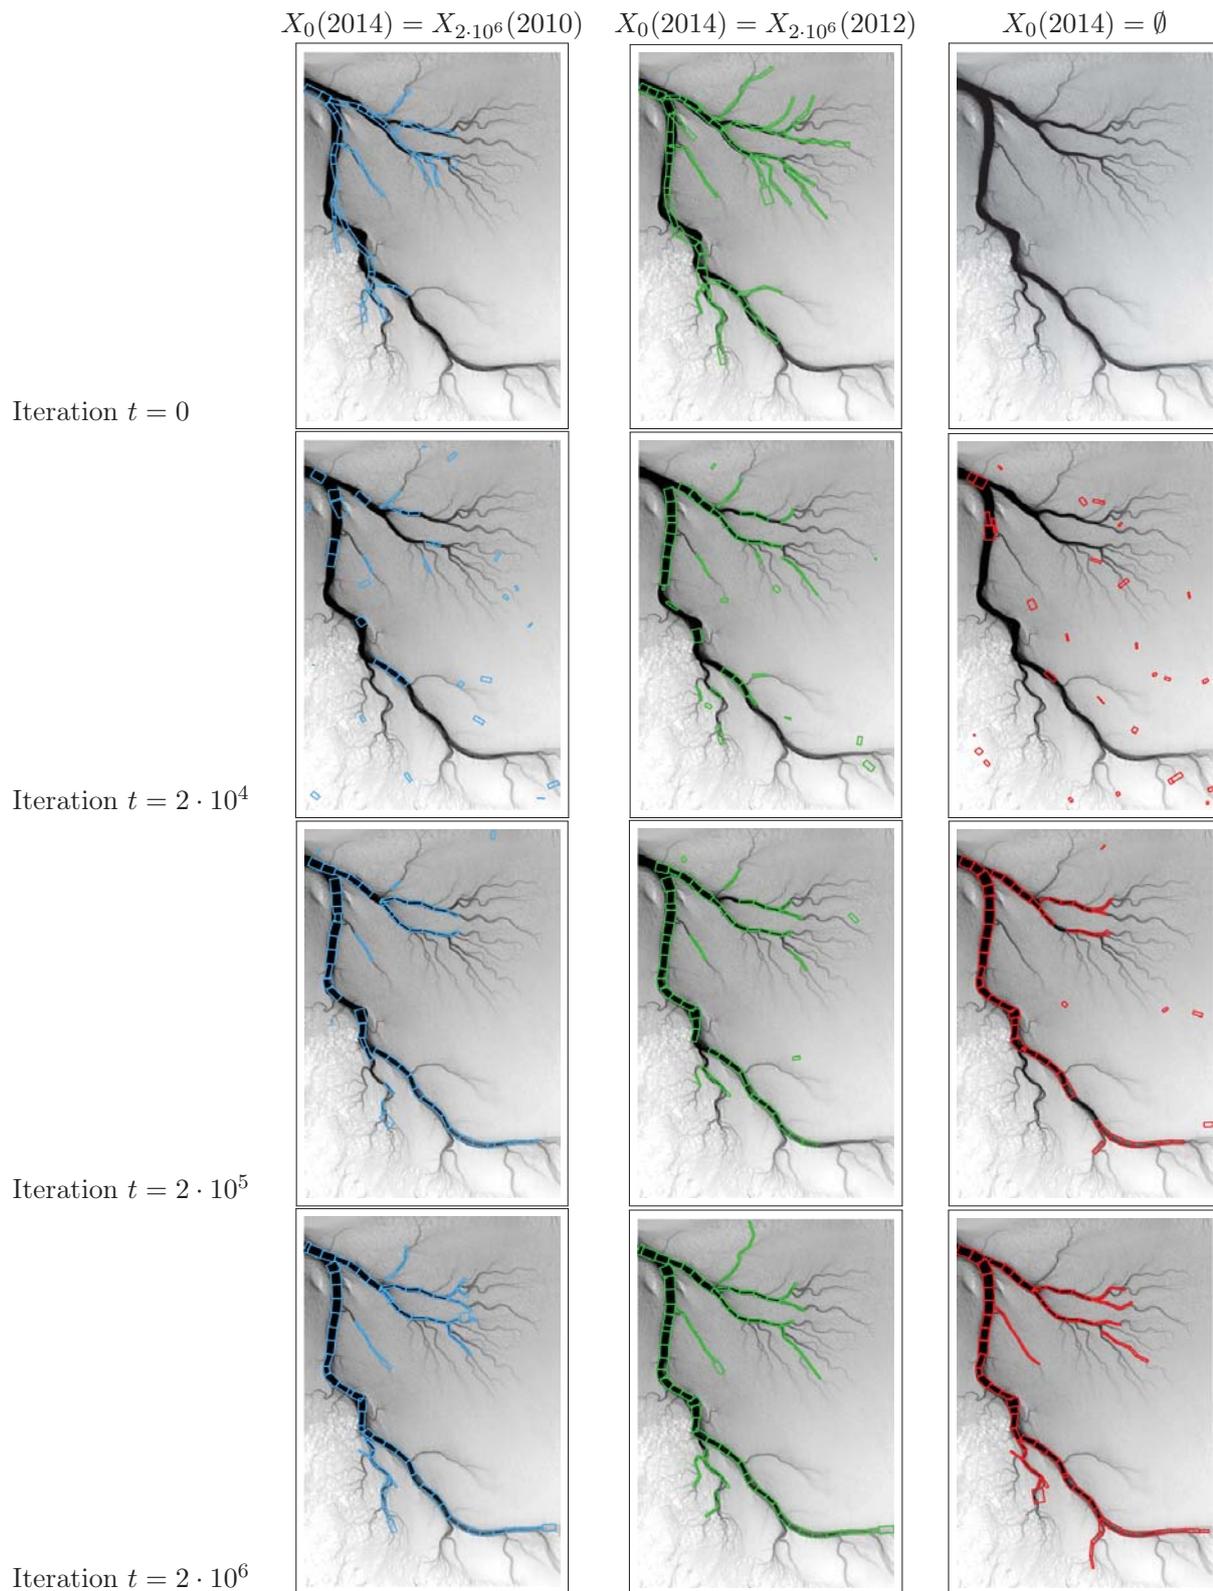
**Ergebnis:** Abbildung 6.18 gibt die Ergebnisse für jede Epoche wieder, sofern keine Vorinformation hinsichtlich der Startkonfiguration im Verfahren berücksichtigt wird. Am Beispiel der Szene aus 2014 ist zudem in Abbildung 6.19 illustriert, wie die Ergebnisse der vorherigen Epoche als Startkonfiguration in das zweite Experiment einfließen. Wird das Ergebnis von 2010 genutzt, d.h.  $X_0(2014) = X_{2 \cdot 10^6}(2010)$ , zeigt die Überlagerung mit dem DGM von 2014, dass nach einem Zeitraum von vier Jahren nahezu keines der Segmentränder mehr mit den Prielerändern übereinstimmt. In den meisten Fällen hat eine zu starke Verlagerung des Netzes stattgefunden. Folglich ist eine Vielzahl an Modifikationen erforderlich bzw. sind die Knoten und Kanten im Graphen zu entfernen und neue hinzuzufügen, um das Prielnetz geeignet zu beschreiben. Nach  $2 \cdot 10^5$  Iterationen sind die großen Priele bereits vollständig extrahiert, nach  $2 \cdot 10^6$  ist das gesamte Netz weitestgehend erkannt. Wird anstelle des Ergebnisses von 2010 dasjenige von 2012 verwendet,  $X_0(2014) = X_{2 \cdot 10^6}(2012)$ , zeigt sich, dass die Startkonfiguration bereits eine höhere Übereinstimmung mit dem aktuellen Prielnetz aufweist. Wie zu erwarten, ist die Differenz der Priele bei einem Zeitabstand von zwei anstelle von vier Jahren



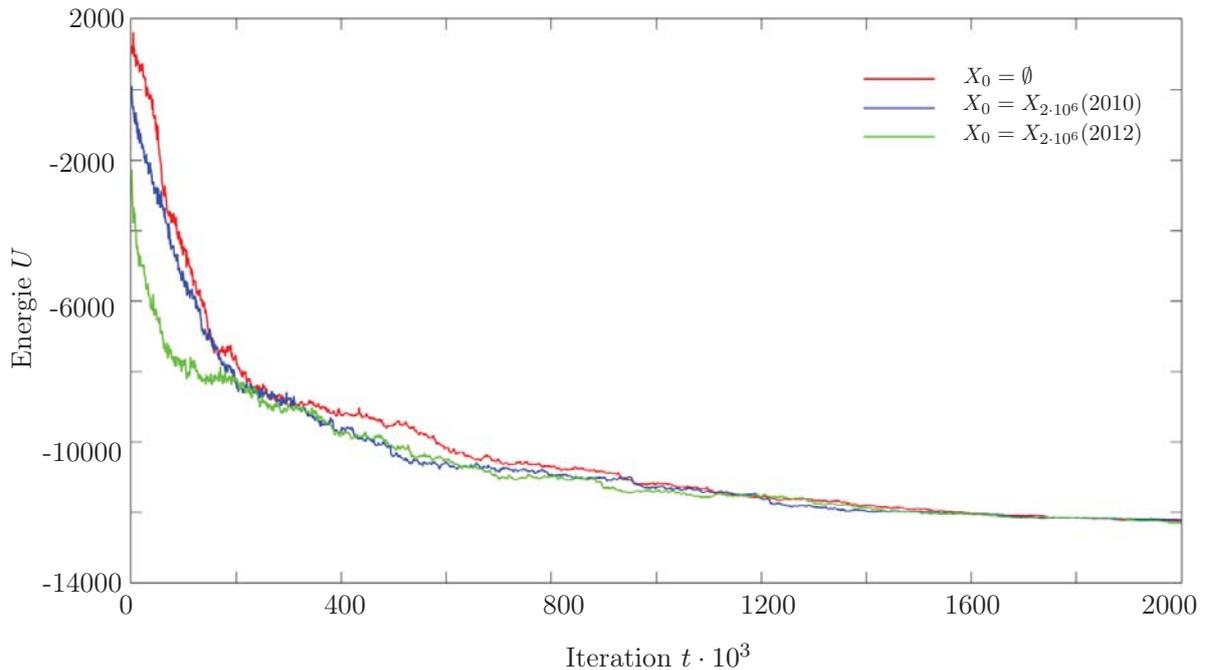
**Abbildung 6.18.:** Innerhalb eines Zeitraums von vier Jahren treten eine Vielzahl von Änderungen im Prielnetz auf, wie im DGM deutlich wird (oben). Für jeden einzelnen Datensatz wird das Prielnetz im *Forest Point Process* abgeleitet (unten).

geringer. Folglich sind eine geringere Anzahl an Änderungen des Graphen vorzunehmen, um eine gute Übereinstimmung mit den Eingangsdaten zu erhalten. Der Wald in der Iteration  $t = 2 \cdot 10^4$  beschreibt das Prielnetz daher deutlich besser als bei Berücksichtigung des Ergebnisses von 2010. In der Iteration  $t = 2 \cdot 10^5$  ähneln sich bereits beide Wälder, im Endergebnis sind nur noch geringfügige Unterschiede im Bereich der kleinen Priele zu erkennen. Fließt keine Vorinformation in den Samplingprozess ein,  $X_0(2014) = \emptyset$ , muss der Suchraum deutlich länger erkundet werden. Nach  $2 \cdot 10^4$  Iterationen stimmen erst wenige Segmente des Waldes mit dem Prielnetz überein. Der große Priel ist weitestgehend nach  $2 \cdot 10^5$  Iterationen gefunden, im Endergebnis von  $2 \cdot 10^6$  Iterationen sind zudem einige der kleineren Zuläufe enthalten.

Die Beobachtungen der Konfigurationen zu den unterschiedlichen Iterationen zeigen sich auch in der Energiekurve (Abbildung 6.20). Unter Berücksichtigung des Ergebnisses von 2012 sinkt die Ener-



**Abbildung 6.19.:** Ergebnis für den Datensatz von 2014, wobei der Graph im Endergebnis der vorherigen Zeitschritte als Startkonfiguration verwendet wird.



**Abbildung 6.20.:** Energiekurven für das Ergebnis des Datensatzes 2014, wenn keine Vorinformation berücksichtigt wird (rot) sowie für den Fall, dass das Ergebnis aus dem Jahr 2010 (blau) bzw. 2012 (grün) einfließt und die Startkonfiguration  $X_0$  bildet.

giekurve rasch ab. Bereits nach ca.  $100 \cdot 10^3$  Iterationen beträgt die Energie  $U = -8000$ , bevor sie anschließend gegen das Minimum von  $U = -12000$  konvergiert. Wird das Ergebnis von 2010 als Startkonfiguration verwendet bzw. fließt kein Vorwissen ein, beginnt die Energiefunktion bei deutlich höheren Startwerten in den ersten Iterationen. Die Energie fällt dann in beiden Fällen ebenfalls rasch ab. Nach etwa  $250 \cdot 10^3$  Iterationen nehmen die Energiewerte zu allen drei Zeitpunkten einen ähnlichen Wert an, nach  $2000 \cdot 10^3$  Iterationen ist in allen Fällen nahezu derselbe Wert erreicht.

**Diskussion:** Für Zeitreihen zeigt sich, dass die Berücksichtigung des Ergebnisses zu einem vorherigen Zeitschritt zu einer schnelleren Konvergenz der Energiekurve gegen das Energieminimum führt. Je kürzer die Beobachtung zurückliegt, umso besser ist das aktuelle Prielnetz durch das Ergebnis der vorherigen Epoche wiedergegeben. Jedoch ist die Beschleunigung der Konvergenz vergleichsweise gering. Bereits nach  $25 \cdot 10^4$  Iterationen nehmen die Energiekurven ähnliche Werte an. Anzumerken ist hierbei, dass die Wahrscheinlichkeiten für die Wahl einer Änderung der Graphkonfiguration für alle Kernel gleich gelassen wurden. In zukünftigen Arbeiten könnte untersucht werden, ob der zeitliche Gewinn durch die schnellere Konvergenz des Verfahrens größer ist, sofern in den anfänglichen Iterationen vermehrt eine Modifikation des Graphen vorgenommen wird. Auf diese Weise ließe sich der initiale Graph an die aktuellen Daten anpassen. Die Wahrscheinlichkeit für die Wahl einer *Birth-and-Death*- sowie einer *Split-and-Merge*-Änderung wiederum könnte zu Beginn klein gewählt werden und erst mit ansteigender Iteration zunehmen, um auch noch neu entstandene Priele zu extrahieren. Darüber hinaus lässt sich in den Ergebnissen erkennen, dass in allen Fällen nahezu derselbe Energiewert als Minimum bestimmt wird. Dies bestätigt die Theorie des RJMCMC-Samplings, nach der das Optimum der Zielfunktion unabhängig von der Startkonfiguration erreicht wird.

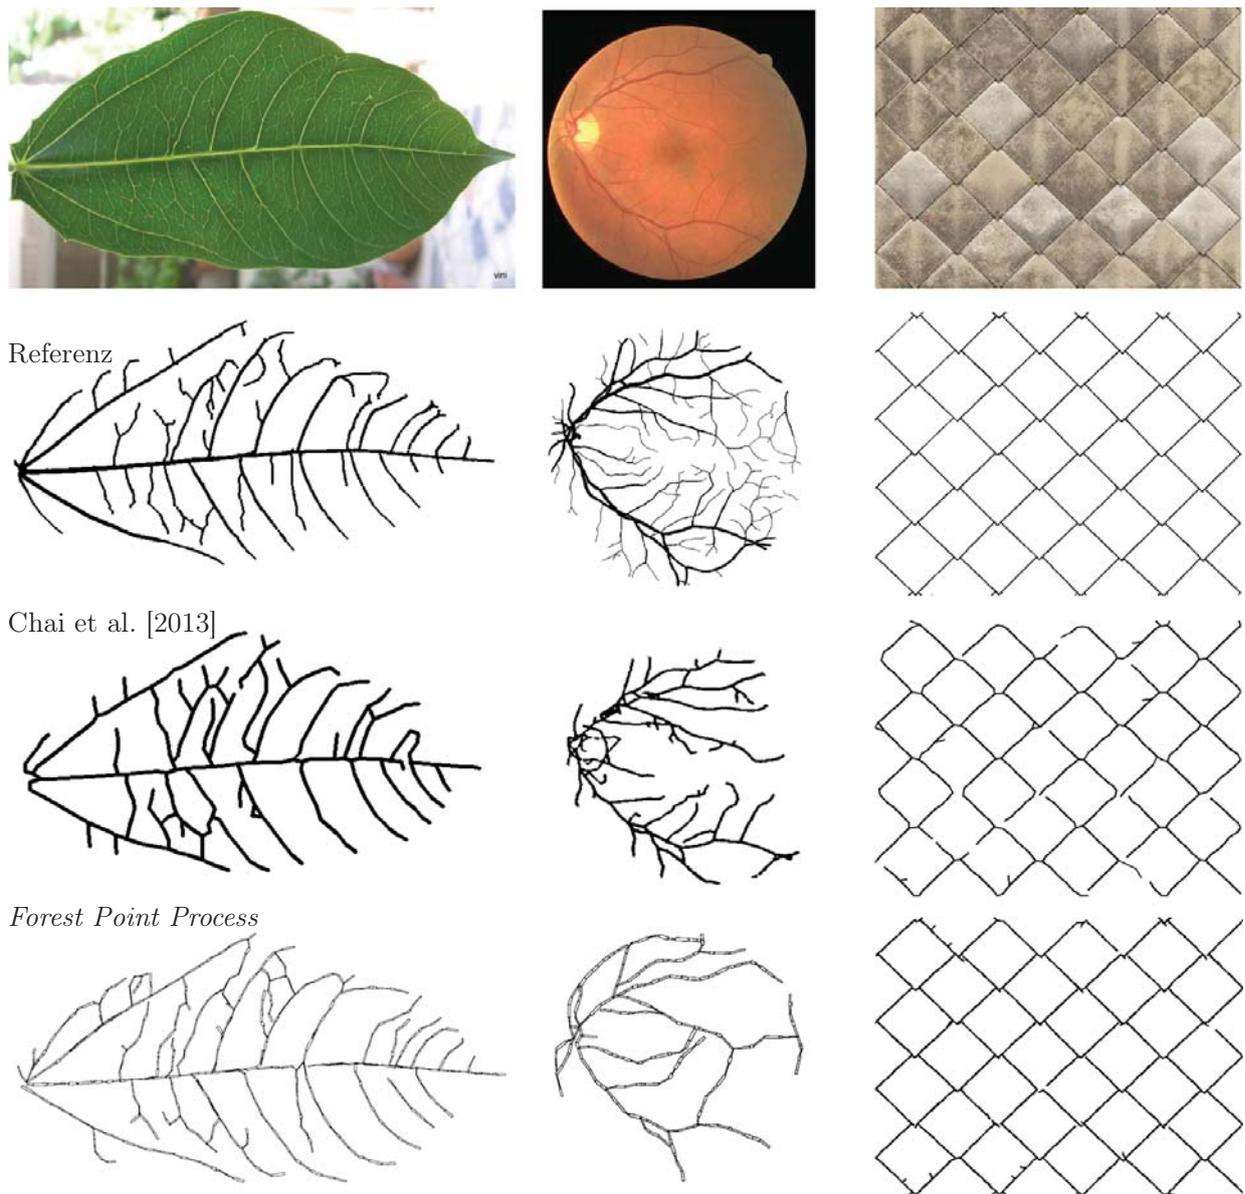
### 6.3. Extraktion von Liniennetzen in Bildern

Die im vorherigen Abschnitt aufgezeigten Ergebnisse haben gezeigt, dass sich das Verfahren des *Forest Point Process* eignet, um Gewässernetze in DGMs zu extrahieren. Die Übertragbarkeit auf Bilder und andere Anwendungsbereiche soll im Folgenden evaluiert werden.

**Experiment:** Neben Gewässernetzen finden sich in der Natur und in künstlichen Objekten zahlreiche weitere Beispiele für Liniennetze. Anhand der Szenen in Abbildung 5.3 wird die Übertragbarkeit des *Forest Point Process* auf Liniennetze in Bildern verifiziert. Hierbei werden im Datenterm anstelle der Höhen des DGM die Grauwerte der Eingangsdaten ausgewertet. Die RGB-Bilder wurden dafür in den HSL-Farbraum (*Hue H, Saturation S, Luminance L* [Agoston, 2005]) transformiert. Die Bilder der relativen Helligkeit (*L*) fließen dann als Eingangsdaten in den *Forest Point Process* ein. Der Priorterm der Fließrichtung  $U_f$  erfüllt im Fall von Gewässernetzen den Nutzen, physikalisch konsistente Netze zu erzeugen. Da hierin unter anderem Liniensegmente gut bewertet werden, die keine Höhengsprünge entlang der Mittelachse aufweisen, kann dieser Term auch für Bilder genutzt werden. Anstelle von Höhen werden die Grauwerte betrachtet, für die homogene Verläufe entlang der Mittelachsen gefordert werden. Für die Ergebnisse werden Qualitätsmaße auf Grundlage der pixelweisen Evaluation (siehe Abschnitt 5.4) abgeleitet, wobei ein Referenzliniennetz für alle Bilder gegeben ist. Zudem liegen die Ergebnisse verschiedener Verfahren aus der Literatur zur Liniennetzextraktion für die einzelnen Szenen vor. Diese werden mit den Ergebnissen des *Forest Point Process* quantitativ verglichen.

**Ergebnis:** Die Ergebnisse des *Forest Point Process* für die Szenen *Blatt, Retina* und *Kacheln* sind in Abbildung 6.21 gemeinsam mit dem Referenzliniennetz und den Ergebnissen des Verfahrens von Chai et al. [2013] abgebildet. Bei letzterem handelt es sich um einen Ansatz basierend auf markierten Punktprozessen. Als Objektmodell ist ebenfalls ein Graph gewählt, jedoch sind für diesen im Gegensatz zum *Forest Point Process* unter anderem Zyklen zugelassen.

Im Ergebnis des *Forest Point Process* lässt sich beobachten, dass weite Teile des Liniennetzes in allen Szenen korrekt erkannt werden. Die großen Adern werden in den Szenen *Blatt* und *Retina* gefunden. Es fehlen lediglich einige der kleineren Strukturen im Netz. Diese sind auch in den Eingangsdaten zum Teil nur schwach zu erkennen, so dass die Summe der Gradienten an den Segmenträndern im Graphen in diesen Bereichen zu keiner ausreichend großen Reduktion der Energiefunktion führt. In der Szene *Kacheln* ist das Liniennetz hingegen komplett aufgefunden. Alle Fugen im Bild sind im Ergebniswald mit Segmenten des *Forest Point Process* abgedeckt. Der quantitative Vergleich der Ergebnisse mit denen des Verfahrens von Chai et al. [2013] zeigt, dass für die Szene *Kacheln* das Liniennetz mit einer signifikant höheren Vollständigkeit und Korrektheit extrahiert wird (siehe Tabelle 6.8). Die Qualität ergibt sich für den *Forest Point Process* (FPP) mit  $Q_{FPP} = 59.6 \%$  im Vergleich zu  $Q_{Chai[2013]} = 36.9 \%$ . Jedoch scheitert der für Bäume konzipierte *Forest Point Process* hinsichtlich der Topologie des Liniennetzes in dieser Szene – was für ein Referenznetz mit Zyklen zu erwarten ist. Kleinere Lücken treten an den Kreuzungen der Fugen auf und der Wald setzt sich daher aus einer Vielzahl von Bäumen zusammen (siehe Abbildung 6.22). Der Graph im Ergebnis für die Szene *Retina* ist hingegen komplett verbunden. Jedoch ist die Qualität des Ergebnisses auf Grund der fehlenden kleinen Strukturen mit  $Q_{FPP} = 37.6 \%$  im Vergleich zu den Ergebnissen von Chai et al. [2013] mit  $Q_{Chai[2013]} = 40.1 \%$  etwas geringer. Für das Adernetz in der Szene *Blatt* ist die Qualität für beide

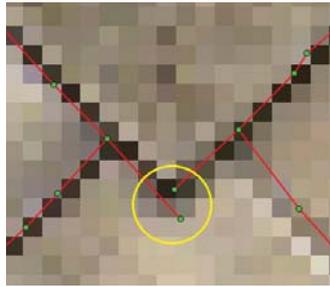


**Abbildung 6.21.:** Ergebnis für verschiedene Liniennetze in Bildern. Das Liniennetz in der Referenz und das Ergebnis des Verfahrens von Chai et al. [2013] sind dabei als Binärbild dargestellt. Für den *Forest Point Process* sind die Umrisse der Segmente gezeigt.

**Tabelle 6.8.:** Quantitativer Vergleich der Ergebnisse des *Forest Point Process* mit dem markierten Punktprozess des Verfahrens von Chai et al. [2013] für Liniennetze in Bildern. Hierfür werden die Maße Korrektheit K [%], Vollständigkeit V [%] und Qualität Q [%] herangezogen.

	<i>Blatt</i>			<i>Retina</i>			<i>Kacheln</i>		
	K	V	Q	K	V	Q	K	V	Q
Chai et al. [2013]	58.8	<b>70.6</b>	<b>47.3</b>	<b>60.4</b>	<b>54.4</b>	<b>40.1</b>	46.2	64.9	36.9
<i>Forest Point Process</i>	<b>69.5</b>	59.7	<b>47.3</b>	57.2	52.2	37.6	<b>65.1</b>	<b>87.6</b>	<b>59.6</b>

Ansätze gleich,  $Q_{FPP} = Q_{Chai[2013]} = 47.3$  %. Insgesamt lassen sich ähnliche Genauigkeiten in beiden Verfahren erzielen.

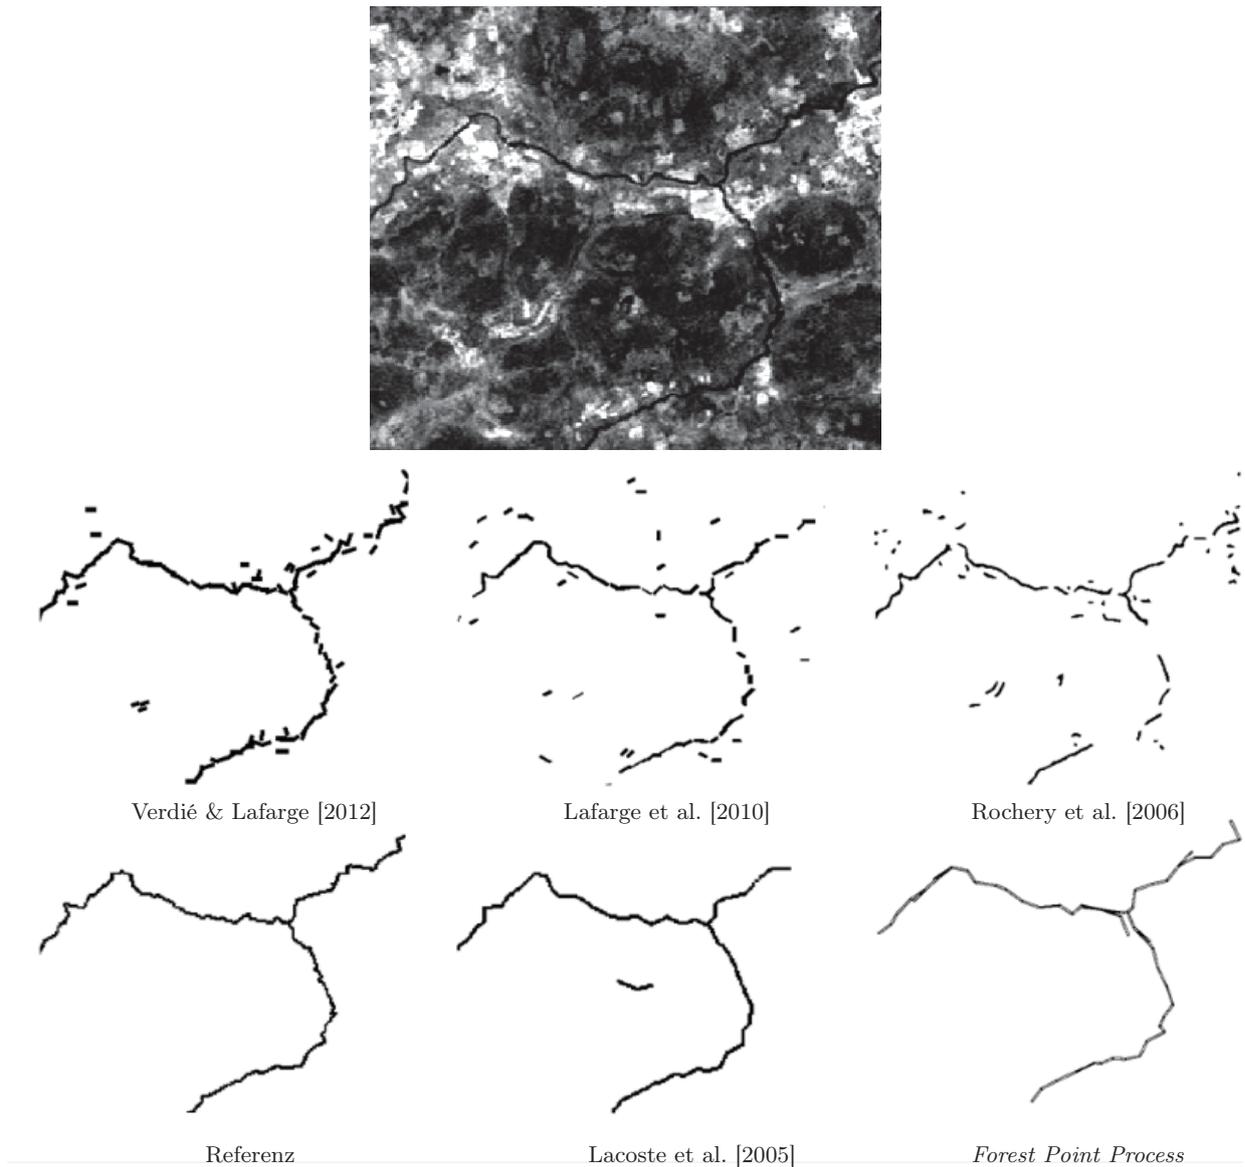


**Abbildung 6.22.:** Bedingt durch das Objektmodell des Waldes können Zyklen nicht abgebildet werden. Für die Szene *Kacheln*, hier in einer detaillierten Ansicht, treten daher Lücken im Netz auf.

Für die Szene *Fluss* liegt das Ergebnis von vier verschiedenen Verfahren aus der Literatur vor. Zum einen handelt es sich hierbei um einen Ansatz basierend auf aktiven Konturen [Rochery et al., 2006], zum anderen um markierte Punktprozesse [Verdié & Lafarge, 2012; Lafarge et al., 2010; Lacoste et al., 2005], bei welchen das Liniennetz jeweils aus einer Menge von Liniensegmenten zusammengesetzt ist. Die Nachbarschaft ist hierbei über die Distanz zwischen den Mittelpunkten [Verdié & Lafarge, 2012] bzw. den Endpunkten der Liniensegmente [Lacoste et al., 2005] definiert. Nah beieinander liegende Endpunkte werden hierbei bevorzugt. Der visuelle Vergleich der Ergebnisse in Abbildung 6.23 zeigt, dass sich das Liniennetz in den Ergebnissen von Rochery et al. [2006], Lafarge et al. [2010] und Verdié & Lafarge [2012] aus einer Vielzahl von unverbundenen Komponenten zusammensetzt. An vielen Stellen weist das Flussnetz Lücken auf. Auch werden im Bild einige Liniensegmente abseits des Flusses fälschlicherweise als solcher detektiert. Im Gegensatz dazu ist das Liniennetz im Ergebnis von Lacoste et al. [2005] komplett erkannt. Abgesehen von einer Fehlklassifikation in der Bildmitte sind die Liniennetze miteinander verbunden. Die Verbundenheit ist hierbei über die euklidischen Distanzen der Segmentendpunkte definiert. Liegen diese nah beieinander, gelten die Segmente als verbunden. Aus dem *Forest Point Process* kann im Gegensatz dazu die Topologie direkt abgeleitet werden. Das Flussnetz ist im Ergebnis nahezu vollständig erkannt und setzt sich aus einem einzelnen Baum zusammen. In wenigen Bereichen (z.B. nahe der mittleren Dreierkreuzung) ist im *Forest Point Process* ein kurzer Abzweig vorgeschlagen, der mit dem Flussnetz im Bild nicht übereinstimmt.

Die Qualitätsmaße der pixelweisen Evaluation zeigen, dass die höchste Qualität für das Ergebnis von Lacoste et al. [2005] mit  $Q_{Lacoste[2005]} = 48.2\%$  erzielt wird (siehe Tabelle 6.9). Der *Forest Point Process* führt nur zu einem geringfügig schlechteren Ergebnis von  $Q_{FPP} = 47.0\%$ . Bezüglich der Vollständigkeit kann hierbei sogar die höchste Rate aller Ergebnisse mit  $V_{FPP} = 66.6\%$  erreicht werden. Insgesamt sind die Qualitätsmaße geringer als der visuelle Vergleich mit den Referenzdaten vermuten lässt (Abbildung 6.23). Dies kann damit begründet werden, dass die Breite der Flüsse mit 2-5 Pixeln sehr gering ist. Sind die Flüsse im Extraktionsergebnis geringfügig zu schmal oder zu breit, wirkt sich dies bereits recht stark auf die Qualitätsmaße auf.

**Diskussion:** Insgesamt zeigt sich, dass der *Forest Point Process*, obwohl für die Flussextraktion in DGMs konzipiert, auch eine gute Eignung für Liniennetze in Bildern aufweist. In ganz unterschiedlichen Szenen werden Liniennetze vergleichsweise gut bis sehr gut erkannt. Soll die Topologie eines azyklischen Netzes abgeleitet werden, weist der *Forest Point Process* klare Vorteile gegenüber Verfahren basierend auf Liniensegmenten auf, da die Topologie durch den Graphen direkt gegeben ist.



**Abbildung 6.23.:** Vergleich des Ergebnisses des *Forest Point Process* mit der Referenz sowie den Verfahren von Rochery et al. [2006], Lacoste et al. [2005], Lafarge et al. [2010] und Verdié & Lafarge [2012] für die Szene *Fluss*.

**Tabelle 6.9.:** Quantitativer Vergleich (Korrektheit K [%], Vollständigkeit V [%] und Qualität Q [%]) mit den Verfahren von Rochery et al. [2006], Lacoste et al. [2005], Lafarge et al. [2010] und Verdié & Lafarge [2012] für die Szene *Fluss*.

	Lacoste [2005]	Rochery [2006]	Lafarge [2010]	Verdie [2012]	<i>Forest Point Process</i>
V	65.1	53.8	47.4	42.9	<b>66.6</b>
K	70.0	49.9	55.0	<b>75.0</b>	61.4
Q	<b>48.2</b>	40.0	34.2	37.5	47.0



## 7. Schlussfolgerungen und Ausblick

In dieser Arbeit wird ein neuer probabilistischer Ansatz für die Extraktion von Liniennetzen in Rasterdaten präsentiert, welcher auf der Methode der markierten Punktprozesse beruht. Das Liniennetz wird dabei mit Hilfe einer Graphstruktur in Form eines Waldes iterativ während des Optimierungsprozesses konstruiert. Der Ansatz wird anhand von digitalen Geländemodellen für die Extraktion von Gewässernetzen evaluiert. Hierbei zeigt sich, dass ein Großteil des Gewässernetzes detektiert wird, sowohl in nahezu horizontalen Gebieten als auch in bergigen Geländeformen. Die Korrektheit und Vollständigkeit des extrahierten Gewässernetzes beträgt  $> 60\%$ . Die geometrische Genauigkeit liegt bei  $< 1$  Pixel für simulierte Daten und Flussnetze in bergigem Gelände, für das Prielnetz im Watt bei  $< 3$  Pixel. Zudem ist eine hierarchische Suchstrategie entwickelt worden, die die Extraktion in unterschiedlichen Auflösungsstufen des DGM erlaubt. Auf diese Weise kann der Suchraum für breite Flüsse in den Daten geringerer Auflösung reduziert werden. Wird Wissen über die Fließrichtung im Gewässernetz in Abhängigkeit der Höhe in das Modell integriert, verbessert sich die Korrektheit der Ergebnisse in allen Fällen, die Zunahme liegt dabei bei bis zu 3 %. Zudem zeigt sich das entwickelte Verfahren gegenüber Standardverfahren zur Flussextraktion bezüglich der Qualitätsmaße überlegen und liefert Ergebnisse mit höheren Genauigkeiten, insbesondere bei nahezu horizontalem Geländeverlauf. Als nachteilig muss jedoch herausgestellt werden, dass das Flussnetz im Gegensatz zu den Ergebnissen der Standardverfahren nicht in allen Bereichen miteinander verbunden ist. Insbesondere beim Zusammenlaufen von Flüssen unterschiedlicher Breite treten Lücken im Ergebnis auf. Grundsätzlich kann das Modell mit Hilfe verschiedener Parameter an unterschiedliche Szenen und für verschiedene Anwendungsbereiche angepasst werden. Gegenüber einigen der Parametern zeigt sich der Ansatz sensitiv. Die Übertragbarkeit des Ansatzes auf Bilder und andere Arten von Liniennetzen ist anhand von mehreren sehr unterschiedlichen Datensätzen aufgezeigt. Auch hier kann ein Großteil des Liniennetzes mit dem vorgeschlagenen Ansatz extrahiert werden. Die Ergebnisse sind darüber hinaus quantitativ vergleichbar mit anderen Ansätzen zur Extraktion von Liniennetzen in der Literatur.

Wenngleich das Verfahren zufriedenstellende Ergebnisse liefert, sind eine Vielzahl von Erweiterungen denkbar. In dem Ansatz werden verschiedene Parameter vom Nutzer vorgegeben. Die Experimente zeigen, dass eine umsichtige Wahl erforderlich ist, um eine geeignete Repräsentation des Liniennetzes zu gewährleisten. Um eine größere Unabhängigkeit von Expertenwissen zu erlangen, ist das Lernen geeigneter Größen für die Parameter Zielsetzung zukünftiger Arbeiten. Das Lernen der Parameter erfordert hierbei die Erstellung von Referenzgraphen in den Trainingsdaten. In diesem Zusammenhang kann die Wahl des Modells in Form eines verbundenen Graphen bestehend aus geradlinigen Liniensegmenten diskutiert werden. Für mäandrierende Gewässernetze stellen diese lediglich eine Näherung dar. Denkbar ist es, anstelle der rechteckigen Liniensegmente andere geometrische Primitive zu modellieren. Mit dem Modell eines Trapezes ließen sich beispielsweise Flüsse mit starken Änderungen der

Flussbreite zutreffender beschreiben. Der Referenzgraph kann zudem genutzt werden, um topologische Qualitätsmaße wie bei Wiedemann [2002] für die Evaluation der Ergebnisse abzuleiten.

Ebenso sind Erweiterungen der Energiefunktion im markierten Punktprozess vorstellbar. Eine Möglichkeit hierfür liegt darin, die Gewichte der einzelnen Daten- und Priorsterme in Abhängigkeit der Iteration zu wählen. Beispielsweise könnte das Gewicht für die Bestrafung nicht-verbundener Graphen zu Beginn sehr gering gesetzt und mit zunehmender Iteration erhöht werden. Auf diese Weise ließe sich die Bestrafung der Vielzahl von Bäumen, die sich durch den iterativen Aufbau des Graphen während des Samplings zwangsläufig in den ersten Iterationen ergibt, vermeiden. Zudem ist es die Zielsetzung zukünftiger Arbeiten, die Anzahl der Lücken im Bereich von zusammenfließenden Flüssen zu reduzieren. Diese lassen sich insbesondere bei der Verbindung von Flüssen unterschiedlicher Breite, welche häufig in verschiedenen Hierarchiestufen extrahiert wurden, beobachten. Hier ist es denkbar, das Gewicht für die Bestrafung überlappender Flächen herabzusetzen. Auch könnte ein zusätzlicher Term bezüglich der Winkel zwischen den Kanten eingeführt werden. Kanten mit Winkeln, wie sie typischerweise beim Zusammenlaufen verschiedener Flüsse auftreten, könnten dann zu einer Reduktion des Wertes der Energiefunktion führen. Typische Winkelkonfigurationen ließen sich wiederum aus Trainingsdaten ableiten.

Eine Anwendungsmöglichkeit des entwickelten Ansatzes wurde in dieser Arbeit für Zeitreihen bei Prielnetzen aufgezeigt. In den Ergebnissen lässt sich erkennen, dass die Berücksichtigung von Vorinformation aus den Ergebnissen vorheriger Zeitpunkte nur geringfügig zu einer Beschleunigung der Konvergenz der Energiefunktion zum Minimum führt. Hier ist es denkbar, in zukünftigen Experimenten den Einfluss der Wahrscheinlichkeit für die Wahl der Änderungskernel der Konfiguration zu untersuchen. So könnten diese beispielsweise in Abhängigkeit der Iteration gewählt werden. Zu Beginn des Samplings würden dann mit einer hohen Wahrscheinlichkeit Modifikationen der bestehenden Graphkonfiguration vorgenommen werden. Mit zunehmender Iteration nähme die Wahrscheinlichkeit zu, bestehende Knoten und Knoten zu entfernen oder neue hinzuzufügen.

Der Graph, der im markierten Punktprozess eingesetzt ist, weist eine Baumstruktur auf. Wenngleich die Wahl eines zyklensfreien Graphen für die Mehrzahl der Flüsse und Priele zutreffend ist, lassen sich Inseln und Sandbänke, die ein Fluss umfließt, damit nicht beschreiben. In der Zukunft könnte das Modell in der Art erweitert werden, dass Zyklen zugelassen sind, aber hinsichtlich ihrer Länge bewertet werden. Zyklen mit sehr kurzen Weglängen, wie sie sich beim Vorliegen von Sandbänken ergeben, erführen demnach keine oder nur eine geringe Bestrafung. Bei zunehmender Weglänge nähme die Bestrafung zu.

Darüber hinaus zeigt sich in den Experimenten, dass mehrere Millionen Iterationen erforderlich sind, um den optimalen Wald in den Eingangsdaten aufzufinden. Für die Beschleunigung der Optimierung ist es denkbar, ein alternatives Verfahren zum RJMCMC-Sampling anzuwenden. So wählen Pham et al. [2016] das Modell einer diskreten Energiefunktion und überführen diese in ein binäres Optimierungsproblem, in welchem sich die optimale Lösung effizient berechnen lässt. Hierfür wäre jedoch eine neue Modellierung der Energiefunktion im vorgestellten Ansatz erforderlich. Eine weitere Möglichkeit liegt in der Parallelisierung des Verfahrens wie bei Verdié & Lafarge [2012, 2014] vorgeschlagen. Die Autoren überführen 2D-Eingangsdaten in die Datenstruktur eines *Quadtree* und

führen in jeder Teilfläche einen unabhängigen Punktprozess durch. Annahmen über die Objektdichte werden aus einer Segmentierung abgeleitet und bestimmen die Größe der Teilfläche. Insgesamt lässt sich eine hohe Parallelisierbarkeit bei diesem Vorgehen beobachten. Eine Übertragung auf den in dieser Arbeit entwickelten Ansatz stellt eine Herausforderung in den Übergangsbereichen der Teilflächen dar. Hier müsste sichergestellt werden, dass ein zusammenhängender Graph als Lösung erzielt werden kann. Es ist vorstellbar, die Suche zunächst in den einzelnen Teilflächen durchzuführen. In einer späteren Iteration, in welcher der optimale Graph weitestgehend in jeder Teilfläche bestimmt ist, könnte dann in einem vergrößerten Objektraum nach Verbindungen zwischen den einzelnen Teilflächen gesucht werden.

Insgesamt zeigt sich, dass mit dem in dieser Arbeit entwickelten Verfahren die geforderten Zielsetzungen erreicht werden konnten. Unter Berücksichtigung der diskutierten Erweiterungen ist zu erwarten, dass ein weiterer Schritt hinsichtlich eines umfassenden Verständnisses bei der Objektextraktion in Rasterdaten für zukünftige Arbeiten möglich ist.



## A. Anhang

Im RJMCMC-Sampling ist der Übergang von der alten Konfiguration  $X$  zur neuen Konfiguration  $X'$  mit Hilfe einer Übergangsfunktion modelliert, deren Jakobi-Determinante in die Berechnung der Green-Ratio (Gleichung 3.11) einfließt. Durch Einführen der Hilfsvariablen  $h$  und  $h'$  gelingt dabei der Übergang in eine andere Dimension des Parameterraums. Am Beispiel der *Birth*-Änderung in Abbildung 4.7 kann dies veranschaulicht werden. Hier wird ein neuer Knoten  $v_6$  mit den Koordinaten  $(x_6, y_6)$  und eine neue Kante  $e_4$  mit der Breite  $w_4$  dem Graphen hinzugefügt. Im Vergleich zur vorherigen Konfiguration erhöht sich die Anzahl an Parametern im Graphen um drei. Alle weiteren Parameter  $Z$  aus der vorherigen Konfiguration bleiben erhalten. Folglich lässt sich der Übergang durch

$$X = \begin{Bmatrix} Z \\ h_1 \\ h_2 \\ h_3 \end{Bmatrix} \rightarrow \begin{Bmatrix} Z \\ x_6 \\ y_6 \\ w_4 \end{Bmatrix} = X' \quad (\text{A.1})$$

formulieren. Die Determinante der Jakobi-Matrix kann wie in Gleichung 3.12 aufgeführt bestimmt werden. Hierfür ergibt sich im Fall der *Birth*-Änderung

$$\det \left( \frac{\partial(X')}{\partial(X, h)} \right) = \det \left( \begin{array}{c|ccc} I & & & \\ \hline & 1 & & \\ & & 1 & \\ & & & 1 \end{array} \right) = 1. \quad (\text{A.2})$$

Der Übergang bei der reversiblen *Death*-Änderung lässt sich mit

$$X = \begin{Bmatrix} Z' \\ x_6 \\ y_6 \\ w_4 \end{Bmatrix} \rightarrow \begin{Bmatrix} Z' \\ h'_1 \\ h'_2 \\ h'_3 \end{Bmatrix} = X' \quad (\text{A.3})$$

darstellen, wobei  $Z'$  die Parameter sind, welche erhalten bleiben. Lediglich die Größen  $x_6$ ,  $y_6$  und  $w_4$  werden entfernt und können den Hilfsvariablen  $h'_1$ ,  $h'_2$  und  $h'_3$  zugeordnet werden. Die Jakobi-Determinante ist dann äquivalent zu Gleichung A.2. Die Herleitung kann analog für den Übergang bei

der Modifikation und der *Split-and-Merge*-Änderung erfolgen. In beiden Fällen beträgt der absolute Wert der Jakobi-Determinanten ebenfalls Eins.

# Literaturverzeichnis

- Agoston MK (2005) *Computer graphics and geometric modeling*. London: Springer.
- Andrieu C, de Freitas N, Doucet A, Jordan MI (2003) An introduction to MCMC for machine learning. *Machine Learning*, 50 (1-2): 5–43.
- Babu GJ, Feigelson ED (1996) Spatial point processes in astronomy. *Journal of Statistical Planning and Inference*, 50 (3): 311–326.
- Baddeley A, van Lieshout M (1993) Stochastic geometry models in high-level vision. *Journal of Applied Statistics*, 20 (5-6): 231–256.
- Bas E, Erdogmus D (2011) Principal Curves as Skeletons of Tubular Objects. *Neuroinformatics*, 9 (2): 181–191.
- Baumgartner A, Steger C, Mayer H, Eckstein W, Ebner H (1999) Automatic road extraction based on multi-scale, grouping, and context. *Photogrammetric Engineering & Remote Sensing*, 65 (7): 777–785.
- Benedek C, Descombes X, Zerubia J (2012) Building development monitoring in multitemporal remotely sensed image pairs with stochastic birth-death dynamics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34 (1): 33–50.
- Benedek C, Martorella M (2014) Moving target analysis in ISAR image sequences with a multiframe marked point process model. *IEEE Transactions on Geoscience and Remote Sensing*, 52 (4): 2234–2246.
- Benmansour F, Cohen LD (2011) Tubular structure segmentation based on minimal path method and anisotropic enhancement. *International Journal of Computer Vision*, 92 (2): 192–210.
- Bentabet L, Jodouin S, Ziou D, Vaillancourt J (2003) Road vectors update using SAR imagery: A snake-based method. *IEEE Transactions on Geoscience and Remote Sensing*, 41 (8): 1785–1803.
- Bishop CM (2006) *Pattern Recognition and Machine Learning*. Berlin: Springer.
- Bondy J, Murty U (2008) Graph Theory. In: *Graduate texts in mathematics*. New York, London: Springer.
- Börcs A, Benedek C (2015) Extraction of Vehicle Groups in Airborne Lidar Point Clouds With Two-Level Point Processes. *IEEE Transactions on Geoscience and Remote Sensing*, 53 (3): 1475–1489.
- Brzank A (2008) Bestimmung Digitaler Geländemodelle in Wattgebieten aus Laserscannerdaten. *Wissenschaftliche Arbeiten der Fachrichtung Geodäsie und Geoinformatik der Leibniz Universität Hannover*, (274).
- Butenuth M, Heipke C (2012) Network snakes: Graph-based object delineation with active contour models. *Machine Vision and Applications*, 23 (1): 91–109.
- Chai D, Förstner W, Lafarge F (2013) Recovering line-networks in images by junction-point processes. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 1894–1901.
- Chai D, Förstner W, Yang MY (2012) Combine Markov Random Fields and marked point processes to extract building from remotely sensed images. In: *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*. I-3: 365–370.
- Chai D, Schmidt A, Heipke C (2016) Detecting linear features by spatial point processes. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. XLI-B3: 841–848.
- Chiu SN, Stoyan D, Kendall WS, Mecke J (2013) *Stochastic geometry and its applications*. Chichester: Wiley, 3. Edition.
- Chothani P, Mehta V, Stepanyants A (2011) Automated tracing of neurites from light microscopy stacks of images. *Neuroinformatics*, 9 (2-3): 263–278.
- Clode S, Rottensteiner F, Kootsookos P, Zelniker E (2007) Detection and Vectorization of Roads from Lidar Detection and Vectorization of Roads from Lidar Data. *Photogrammetric Engineering & Remote Sensing*, 73 (4): 517–536.
- Craig JJ (2005) *Introduction to Robotics: Mechanics and Control*. Pearson, 3. Edition.
- Daley D, Vere-Jones D (2003) *An introduction to the theory of point processes: Volume I: Elementary theory and methods*. New York, Berlin, Heidelberg: Springer, 2. Edition.
- Descamps S, Descombes X, Béchet A, Zerubia J (2008) Automatic flamingo detection using a multiple birth and death process. *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*, : 304–306.
- Descombes X (2012) Interacting adaptive filters for multiple objects detection. In: Florack L, Duits R, Jongbloed G, Van Lieshout M (Ed.) *Mathematical methods for signal and image analysis and representation* Kapitel 13, (S. 241–264). Springer.
- Descombes X, Minlos R, Zhizhina E (2009) Object extraction using a stochastic birth-and-death dynamics in continuum. *Journal of Mathematical Imaging and Vision*, 33 (3): 347–359.

- Descombes X, Zerubia J (2002) Marked point process in image analysis. *IEEE Signal Processing Magazine*, 19 (5): 77–84.
- Diestel R (2010) *Graphentheorie*. Heidelberg Dordrecht London New York: Springer, 4. Edition.
- Diggle PJ (2003) *Statistical Analysis of Spatial Point Patterns*. London: Arnold, 2. Edition.
- Elstrodt J (2010) *Maß- und Integrationstheorie*. Berlin, Heidelberg: Springer, 7. Edition.
- Europäische Kommission (1992) Council Directive 92/43/EEC of 21 May 1992 on the conservation of natural habitats and of wild fauna and flora. *Amtsblatt der Europäischen Union*, L 206: 1–66.
- Europäische Kommission (2000) Directive 2000/60/EC of the European Parliament and of the Council of 23 October 2000 establishing a framework for Community action in the field of water policy. *Amtsblatt der Europäischen Union*, L 327: 1–72.
- Europäische Kommission (2008) Directive 2008/56/EC of the European Parliament and of the Council of 17 June 2008 establishing a framework for community action in the field of marine environmental policy (Marine Strategy Framework Directive). *Amtsblatt der Europäischen Union*, L 164: 19–40.
- Fagherazzi S, Bortoluzzi A, Dietrich WE, Adami A, Lanzoni S, Marani M, Rinaldo A (1999) Tidal networks - Automatic network extraction and preliminary scaling features from digital terrain maps. *Water Resources Research*, 35 (12): 3891–3904.
- Fairfield J, Leymarie P (1991) Drainage network from grid digital elevation models. *Water Resources Research*, 27 (5): 709–717.
- Fischler MA, Tenenbaum JA, Wolf HC (1981) Detection of roads and linear structure in low resolution aerial imagery using a multi-source knowledge integration technique. *Computer Graphics and Image Processing*, 15 (3): 201–223.
- Fleischer F, Beil M, Kazda M, Schmidt V (2006) Analysis of spatial point patterns in microscopic and macroscopic biological image data. In: Baddeley A, Gregori P, Mateu J, Stoica R, Stoyan D (Ed.) *Case studies in spatial point process modeling* (S. 235–260). New York: Springer.
- Freeman TG (1991) Calculating catchment area with divergent flow based on a regular grid. *Computers and Geosciences*, 17 (3): 413–422.
- Fua P (1997) Model-based optimization: An approach to fast, accurate, and consistent site modeling from imagery. *RADIUS: Image Understanding for Intelligence Imagery*, : 903–908.
- Gamba P, Dell’Acqua F, Lisini G (2006) Improving urban road extraction in high-resolution images exploiting directional filtering, perceptual grouping, and simple topological concepts. *IEEE Geoscience and Remote Sensing Letters*, 3 (3): 387–391.
- Ge W, Collins RT (2009) Marked point processes for crowd counting. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, : 2913–2920.
- Geman D, Jedynak B (1996) An active testing model for tracking roads in satellite images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18 (1): 1–14.
- Geman S, Geman D (1984) Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6 (6): 721–741.
- Gerke M, Butenuth M, Heipke C, Willrich F (2004) Graph-supported verification of road databases. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58 (3-4): 152–165.
- Geyer CJ, Møller J (1994) Simulation procedures and likelihood inference for spatial point processes. *Scandinavian Journal of Statistics*, 21 (4): 359–373.
- Göpfert J, Rottensteiner F, Heipke C (2011) Using snakes for the registration of topographic road database objects to ALS features. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (2011): 858–871.
- Green PJ (1995) Reversible jump Markov Chain Monte Carlo computation and Bayesian model determination. *Biometrika*, 82 (4): 711–732.
- Grote A, Heipke C, Rottensteiner F (2012) Road network extraction in suburban areas. *Photogrammetric Record*, 27 (137): 8–28.
- Gruber S, Peckham S (2009) Land-surface parameters and objects in hydrology. In: Hengl T, Reuter HI (Ed.) *Developments in Soil Science*, Vol. 33 Kapitel 7, (S. 171–194). Elsevier.
- Gruen A, Li H (1995) Road extraction from aerial and satellite images by dynamic programming. *ISPRS Journal of Photogrammetry and Remote Sensing*, 50 (4): 11–20.
- Hastings W (1970) Monte Carlo sampling methods using Markov chains and their applications. *Biometrika*, 57 (1): 97–109.
- Hervieu A, Soheilian B, Brédif M (2015) Road marking extraction using a model & data-driven RJ-MCMC. In: *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*. II-3/W4: 47–54.
- Hinz S, Baumgartner A (2003) Automatic extraction of urban road networks from multi-view aerial imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58 (1-2): 83–98.

- Holmgren P (1994) Multiple flow direction algorithms for runoff modelling in grid based elevation models: An empirical evaluation. *Hydrological Processes*, 8 (4): 327–334.
- Hu J, Razdan A, Femiani JC, Cui M, Wonka P (2007) Road network extraction and intersection detection from aerial images by tracking road footprints. *IEEE Transactions on Geoscience and Remote Sensing*, 45 (12): 4144–4157.
- Huang H, Brenner C, Sester M (2013) A generative statistical approach to automatic 3D building roof reconstruction from laser scanning data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 79 (2013): 29–43.
- Hughes ZJ (2012) Tidal channels on tidal flats and marshes. In: Davis RA, Dalrymple RW (Ed.) *Principles of Tidal Sedimentology* Kapitel 11, (S. 269–300). Dordrecht, Heidelberg, London, New York: Springer.
- Jasiewicz J, Metz M (2011) A new GRASS GIS toolkit for Hortonian analysis of drainage networks. *Computers and Geosciences*, 37 (8): 1162–1173.
- Kass M, Witkin A, Terzopoulos D (1988) Snakes: Active contour models. *International Journal of Computer Vision*, 1 (4): 321–331.
- Katartzis A, Sahli H, Pizurica V, Cornelis J (2001) A model-based approach to the automatic extraction of linear features from airborne images. *IEEE Transactions on Geoscience and Remote Sensing*, 39 (9): 2073–2079.
- Kirbas C, Quek F (2004) A review of vessel extraction techniques and algorithms. *Computing Surveys*, 36 (2): 81–121.
- Kirkpatrick S, Gelatt C, Vecchi M (1983) Optimization by simulated annealing. *Science, New Series*, 220 (4598): 671–680.
- Koutaki G, Uchimura K, Hu Z (2006) Refining road map using active shape model from aerial. *Vision Geometry, Proceedings of SPIE-IS&T Electronic Imaging*, 6066: 1–10.
- Kraus K, Pfeifer N (1998) Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 53 (1998): 193–203.
- Kreher BW (2007) Detektion von Hirnnervenfasern auf der Basis von diffusionsgewichteten Magnetresonanzdaten. *Dissertation der Fakultät für Angewandte Wissenschaften der Albert-Ludwigs-Universität Freiburg im Breisgau*.
- Kumar S, Hebert M (2003) Discriminative Random Fields: A discriminative framework for contextual interaction in classification. *Proceedings of IEEE International Conference on Computer Vision*, 2: 1150–1157.
- Kuntzsch C, Sester M, Brenner C (2016) Generative models for road network reconstruction. *International Journal of Geographical Information Science*, 30 (5): 1012–1039.
- Lacoste C, Descombes X, Zerubia J (2005) Point processes for unsupervised line network extraction in remote sensing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27 (10): 1568–1579.
- Lacoste C, Finet G, Magnin I (2006) Coronary tree extraction from X-ray angiograms using marked point processes. In: *Proceedings of IEEE International Symposium on Biomedical Imaging* (1): 157–160.
- Lafarge F, Gimel'Farb G, Descombes X (2010) Geometric feature extraction by a multimarked point process. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32 (9): 1597–1609.
- Law MWK, Chung ACS (2010) An oriented flux symmetry based active contour model for three dimensional vessel segmentation. In: *European Conference on Computer Vision (ECCV) 2010*. Berlin, Heidelberg: Springer, LNCS 6313: 720–734.
- Lea N (1992) An aspect-driven kinematic routing algorithm. In: Parsons AJ, Abrahams AD (Ed.) *Overland flow: Hydraulics and erosion mechanics* Kapitel 16, (S. 147–175). New York: Chapman & Hall/CRC.
- Lesage D, Angelini ED, Bloch I, Funke-Lea G (2009) A review of 3D vessel lumen segmentation techniques: Models, features and extraction schemes. *Medical Image Analysis*, 13 (6): 819–845.
- Li SZ (1995) *Markov random field modeling in computer vision*. Tokyo: Springer.
- Li Y, Li J (2010) Oil spill detection from SAR intensity imagery using a marked point process. *Remote Sensing of Environment*, 114 (7): 1590–1601.
- Liu J (2004) Monte Carlo strategies in scientific computing. In: *Springer Series in Statistics*. New York: Springer.
- Lohani B, Mason DC (2001) Application of airborne scanning laser altimetry to the study of tidal channel geomorphology. *ISPRS Journal of Photogrammetry and Remote Sensing*, 56 (2): 100–120.
- Lohani B, Mason DC, Scott TR, Sreenivas B (2006) Extraction of tidal channel networks from aerial photographs alone and combined with laser altimetry. *International Journal of Remote Sensing*, 27 (1): 5–25.
- Ludwig J, Reynolds J (1988) *Statistical Ecology: A Primer on Methods and Computing*. New York: John Wiley & Sons.
- MacKay DJC (2003) *Information Theory and Learning Algorithms*, Vol. 22. Cambridge, UK: Cambridge University Press.

- Mallet C, Lafarge F, Roux M, Sörgel U, Bretar F, Heipke C (2010) A marked point process for modeling lidar waveforms. *IEEE Transactions on Image Processing*, 19 (12): 3204–3221.
- Marín D, Aquino A, Gegúndez-arias ME, Bravo JM (2011) A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features. *IEEE Transactions on Medical Imaging*, 30 (1): 146–158.
- Marshall A (1956) The use of multistage sampling schemes in Monte Carlo computations. In: Meyer H (Ed.) *Symposium on Monte Carlo Methods* (S. 123–140). Wiley.
- Mason DC, Scott TR, Wang HJ (2006) Extraction of tidal channel networks from airborne scanning laser altimetry. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61 (2): 67–83.
- Mayer H, Hinz S, Bacher U, Baltsavias E (2006) A test of automatic road extraction approaches. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. XXXVI (3): 209–214.
- Mayer H, Reznik S (2007) Building facade interpretation from uncalibrated wide-baseline image sequences. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61: 371–380.
- McKeown DM, Denlinger JL (1988) Road tracking in aerial imagery. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 662–672.
- Metropolis N, Rosenbluth AW, Rosenbluth M, Teller A (1953) Equation of state calculations by fast computing machines. *Journal of Chemical Physics*, 21 (6): 1087–1092.
- Mnih V, Hinton GE (2010) Learning to detect roads in high-resolution aerial images. In: *European Conference on Computer Vision (ECCV) 2010*. Berlin, Heidelberg: Springer, LNCS 6316: 210–223.
- Møller J, Waagepetersen R (2004) *Statistical inference and simulation for spatial point processes*. Boca Raton: Chapman & Hall/CRC.
- Montoya-Zegarra J, Wegner J, Ladicky L, Schindler K (2014) Mind the gap: modeling local and global context in (road) networks. *German Conference on Pattern Recognition (GCPR)*.
- Movaghati S, Moghaddamjoo A, Member S, Tavakoli A (2010) Road extraction from satellite images using particle filtering and extended Kalman filtering. *IEEE Transactions on Geoscience and Remote Sensing*, 48 (7): 2807–2817.
- Nikodym O (1930) Sur une généralisation des intégrales de M. J. Radon. *Fundamenta Mathematicae*, 15 (1): 131–179.
- O’Callaghan JF, Mark DM (1984) The extraction of drainage networks from digital elevation data. *Computer Vision, Graphics, and Image Processing*, 28: 323–344.
- Ortner M, Descombes X, Zerubia J (2007) Building outline extraction from digital elevation models using marked point processes. *International Journal of Computer Vision*, 72 (2): 107–132.
- Ortner M, Descombes X, Zerubia J (2008) A marked point process of rectangles and segments for automatic analysis of digital elevation models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30 (1): 105–119.
- Osher S, Sethian JA (1988) Fronts propagating with curvature dependent speed: Algorithms based on Hamilton-Jacobi formulations. *Journal of Computational Physics*, 79: 12–49.
- Parker J (2011) *Algorithms for Image Processing and Computer Vision*. Wiley, 2. Edition.
- Perrin G, Descombes X, Zerubia J (2005) Adaptive simulated annealing for energy minimization problem in a marked point process application. In: *Energy Minimization Methods in Computer Vision and Pattern Recognition*. Berlin, Heidelberg: Springer, LNCS 3757: 3–17.
- Perrin G, Descombes X, Zerubia J (2006) Point processes in forestry : an application to tree crown detection. *INRIA, Research Report 5544*.
- Pham TT, Rezatofighi SH, Reid I, Chin Tj (2016) Efficient point process inference for large-scale object detection. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 2837–2845.
- Poullis C, You S (2010) Delineation and geometric modeling of road networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65 (2): 165–181.
- Quinn P, Beven K, Chevallier P (1991) The prediction of hillslope flow paths for distributed hydrological modelling using digital terrain models. *Hydrological Processes*, 5 (1): 59–79.
- Richardson S, Green PJ (1997) On bayesian analysis of mixtures with an unknown number of components. *Journal of the Royal Statistical Society. Series B (Methodological)*, 59 (4): 731–792.
- Ripperda N, Brenner C (2006) Reconstruction of façade structures using a formal grammar and RjM-CMC. In: *Proceedings of the 28th DAGM Symposium, Berlin, Germany*: 750–759.
- Rochery M, Jermyn IH, Zerubia J (2006) Higher order active contours. *International Journal of Computer Vision*, 69 (1): 27–42.
- Romeo F, Sangiovanni-Vincentelli A (1991) A theoretical framework for Simulated Annealing. *Algorithmica*, 6: 302–345.

- Rue V, Sciences M, Lieshout V, Carlo M (1999) Bayesian object identification. *Biometrika*, 86 (3): 649–660.
- Salamon P, Sibani P, Frost R (2002) Facts, conjectures, and improvements for simulated annealing. Philadelphia: Society for Industrial and Applied Mathematics.
- Schmidt A, Kruse C, Rottensteiner F, Soergel U, Heipke C (2016) Network detection in raster data using marked point processes. In: *ISPRS Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. XLI-B3: 701–708.
- Schmidt A, Niemeyer J, Rottensteiner F, Soergel U (2014) Contextual classification of full waveform lidar data in the Wadden Sea. *IEEE Geoscience and Remote Sensing Letters*, 11 (9): 1614–1618.
- Schmidt A, Rottensteiner F, Soergel U (2013) Water-land-classification in coastal areas with full waveform lidar data. *Photogrammetrie, Fernerkundung, Geoinformation*, 2 (2013): 71–81.
- Siarry P, Berthiau G, Durbin F, Haussy J (1997) Enhanced Simulated Annealing for Globally Minimizing Functions of Many- Continuous Variables. *ACM Transactions on Mathematical Software*, 23 (2): 209–228.
- Smith K (2007) Bayesian methods for visual multi-object tracking with applications to human activity recognition. *Doktorarbeit der Eidgenössischen Technischen Hochschule Lausanne*, 3745.
- Stoica R, Descombes X, Zerubia J (2004) A Gibbs point process for road extraction from remotely sensed images. *International Journal of Computer Vision*, 57 (2): 121–136.
- Stoica RS, Martínez VJ, Saar E (2007) A three-dimensional object point process for detection of cosmic filaments. *Journal of the Royal Statistical Society. Series C: Applied Statistics*, 56 (4): 459–477.
- Strzodka R, Telea A (2004) Generalized distance transforms and skeletons in graphics hardware. In: *Proceedings of EG/IEEE TCVG Symposium on Visualization 2004*: 221–230.
- Sun K, Sang N, Zhang T (2007) Marked point process for vascular tree extraction on angiogram. In: *Energy Minimization Methods in Computer Vision and Pattern Recognition*. Berlin, Heidelberg: Springer, LNCS 4679: 467–478.
- Szeliski R (2010) *Computer Vision: Algorithms and Applications*. New York: Springer.
- Tournaire O, Brédif M, Boldo D, Durupt M (2010) An efficient stochastic approach for building footprint extraction from digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65 (4): 317–327.
- Tournaire O, Paparoditis N (2009) A geometric stochastic approach based on marked point processes for road mark detection from high resolution aerial images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (6): 621–631.
- Tu ZW, Zhu SC (2002) Image segmentation by data-driven Markov Chain Monte Carlo. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24 (5): 657–673.
- Tupin F, Maître H, Mangin JF, Nicolas JM, Pechersky E (1998) Detection of linear features in SAR images: Application to road network extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 36 (2): 434–453.
- Türetken E, Benmansour F, Andres B, Pfister H, Fua P (2013) Reconstructing loopy tubular structures using integer programming. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, : 1882–1829.
- Türetken E, Benmansour F, Fua P (2012) Automated reconstruction of tree structures using path classifiers and mixed integer programming. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 566–573.
- Utasi Á, Benedek C (2011) A 3-D marked point process model for multi-view people detection. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 3385–3392.
- Van Lieshout NM (2000) *Markov point processes and their applications*. London: Imperial College Press.
- Verdié Y, Lafarge F (2012) Efficient Monte Carlo sampler for detecting parametric objects in large scenes. In: *European Conference on Computer Vision (ECCV) 2012*. Berlin, Heidelberg: Springer, LNCS 7574: 539–552.
- Verdié Y, Lafarge F (2014) Detecting parametric objects in large scenes by Monte Carlo sampling. *International Journal of Computer Vision*, 106 (1): 57–75.
- Vetter M, Mandlbürger G (2014) Modification of high resolution airborne laser scanning DTMs for drainage network delineation. *Photogrammetrie, Fernerkundung, Geoinformation*, 1 (2014): 41–54.
- von Dienst HR, Mack T, Feilmeier M, Bertram J, Helten E, Reichel G (2002) Beiträge zum versicherungsmathematischen Grundwissen. In: Helbig M (Ed.) *Versicherungs- und Finanzmathematik, Band 12* (S. 159). 2. Edition.
- von Neumann J (1951) Various techniques used in connection with random digits. In: *Applied Mathematics Series*, Vol. 12 (S. 36–38).
- Vosselman G, de Knecht J (1995) Road tracing by profile matching and Kalman filtering. In: Gruen A,

- Kuebler O, Agouris P (Ed.) *Automatic extraction of man-made objects from aerial and space images* (S. 265–276). Basel, Boston, Berlin: Birkhäuser.
- Wang Y, Narayanaswamy A, Roysam B (2011) Novel 4-D open-curve active contour and curve completion approach for automated tree structure extraction. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*: 1105–1112.
- Wegner JD, Montoya-Zegarra JA, Schindler K (2015) Road networks as collections of minimum cost paths. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108 (2015): 128–137.
- Wengenroth J (2008) *Wahrscheinlichkeitstheorie*. Berlin, New York: Walter de Gruyter.
- Wenzel S (2016) High-level facade image interpretation using marked point processes. *Dissertation der Landwirtschaftlichen Fakultät der Rheinischen Friedrich-Wilhelms-Universität Bonn*.
- Wiedemann C (2002) Extraktion von Straßennetzen aus optischen Satellitenbilddaten. *Doktorarbeit der Fakultät für Bauingenieur- und Vermessungswesen der Technischen Universität München*.
- Wiedemann C, Heipke C, Mayer H, Jamet O (1998) Empirical evaluation of automatically extracted road axes. In: *CVPR Workshop on Empirical Evaluation Methods in Computer Vision*: 172–187.
- Wilson JP, Aggett G, Yongxin D, Lam CS (2008) Water in the landscape: a review of contemporary flow routing algorithms. In: Zhou Q, Lees B, Tang GA (Ed.) *Advances in Digital Terrain Analysis* (S. 213–236). Berlin: Springer.
- Winter C, Herrling G, Bartholomä A, Capperucci R, Callies U, Heipke C, Schmidt A, Hillebrand H, Reimers C, Bremer P, Weiler R (2014) Wissenschaftliche Konzepte für ein Monitoring des ökologischen Zustands des deutschen Küstenmeeres. *Wasser und Abfall*, 7-8: 21–26.
- Zhang C (2004) Towards an operational system for automated updating of road databases by integration of imagery and geodata. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58 (3-4): 166–186.
- Zhang J, Sohn G, Brédif M (2013) Single tree detection from airborne laser scanning data using a marked point process based method. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. II-3/W1: 41–46.
- Zhao T, Xie J, Amat F, Clack N, Ahammad P, Peng H, Long F, Myers E (2011) Automated reconstruction of neuronal morphology based on local geometrical and global structural models. *Neuroinformatics*, 9 (2-3): 247–261.

---

# Lebenslauf

## Persönliches

Alena Hanna Charlotte Schmidt

05. Februar 1986, Hildesheim

## Beruflicher Werdegang

seit 12/2010	Wissenschaftliche Mitarbeiterin am Institut für Photogrammetrie und GeoInformation, Leibniz Universität Hannover
2008 - 2014	Vermesserin und Kartiererin bei verschiedenen Forschungsprojekten in Ägypten (Luxor und Edfu), im Auftrage des Britischen Museums London, der Ludwig-Maximilians-Universität München, des Deutschen Archäologischen Instituts Kairo

## Ausbildung

10/2008 - 10/2010	Studium der Geodäsie und Geoinformatik an der Leibniz Universität Hannover, Abschluss: Master of Science
11/2008 - 12/2008	Studium am Dublin Institute of Technology, Irland
10/2005 - 10/2008	Studium der Geodäsie und Geoinformatik an der Leibniz Universität Hannover, Abschluss: Bachelor of Science
08/1992 - 07/2005	Grundschule Bockenem, Gymnasium Marienschule Hildesheim, Abschluss: Abitur