

Kombinatorische Lösungen für Segmentierungsprobleme im Maschinensehen

Thomas Schoenemann

Centre for Mathematical Sciences
Lund University, Sweden
tosch@maths.lth.se

Abstract: Wir präsentieren modellbasierte Lösungsansätze für eine Vielzahl von Segmentierungsproblemen im Gebiet des Maschinensehens, wobei die Segmentierung von Bildern und Videos behandelt wird. In allen Fällen werden die Probleme zunächst als Minimierung geeigneter Kostenfunktionen formuliert, dann werden Verfahren entwickelt, um lokale oder globale Minima zu finden. Dabei kommen sowohl diskrete als auch kontinuierliche Verfahren zum Einsatz.

1 Einführung

Das Gebiet des Maschinensehens (engl. *Computer Vision*) befasst sich mit einer Vielzahl von Inferenzproblemen: gegeben ein Bild oder eine Menge von Bildern, versucht man, die Eigenschaften der 3D-Szene, die das Bild/die Bilder generiert haben, mittels automatischer Verfahren zu rekonstruieren. Welche Eigenschaften von Interesse sind, hängt dabei von der jeweiligen Aufgabenstellung ab.

In der Bewegungsschätzung ist man daran interessiert, an welcher Stelle die Pixel des ersten von zwei (zeitlich aufeinanderfolgenden) Bildern im zweiten Bild zu finden sind. Beim Problem der Bildsegmentierung möchte man das Bild in zusammengehörige Regionen unterteilen. Ein Mensch würde die jeweiligen Regionen als Objekte interpretieren. Man muss hier aber vom Problem der Objekterkennung unterscheiden: ein Segmentierungsproblem identifiziert nur die Regionen im Bild, es gibt keinerlei Auskunft darüber, ob sich beispielsweise ein Stuhl im Bild befindet.

In allen Fällen lassen sich die gesuchten Informationen leicht als mathematische Objekte (Funktionen, Mengen, Relationen etc.) formulieren. Ist die Aufgabe etwa, ein Graustufenbild $I : \Omega \rightarrow \mathbb{R}$, definiert auf einer rechteckigen Domäne Ω , in maximal L Regionen zu zerlegen, so sucht man nach einer Funktion $l : \Omega \rightarrow \{1, \dots, L\}$. Damit ist der erste Schritt getan, um ein reales Problem mittels eines Computers zu lösen. Es gibt jedoch eine Vielzahl von Funktionen l , die in Frage kommen, und welche davon gewünscht ist hängt offensichtlich vom jeweiligen Eingabebild I ab.

Dieser Artikel verfolgt, wie eine Vielzahl relevanter Vorarbeiten (etwa [HS81, MS89, AWJ90, CYES01, JI01, BT99, CY03, JF01]), einen strengen *modellbasierten* Ansatz, wo-

bei die gewünschte Lösung als Minimum einer Kostenfunktion spezifiziert wird. Dabei ergeben sich für jede neue Aufgabenstellung zwei Probleme:

- Was ist eine geeignete Kostenfunktion für die Problemstellung?
- Wie lassen sich globale oder gute lokale Minima der Kostenfunktion berechnen?

In der Praxis müssen diese beiden Punkte gemeinsam behandelt werden: es ist allgemein bekannt, dass bereits wenig komplexe Kostenfunktionen, wie etwa die des bekannten *Traveling Salesman Problems*, in sehr schwierigen (NP-harten) Optimierungsproblemen resultieren. Dies liegt insbesondere daran, dass die Anzahl der Objekte über die minimiert wird in der Regel exponentiell groß oder sogar unendlich ist und eine sequentielle Behandlung jeder einzelnen Lösung damit nicht in Frage kommt.

Dieser Artikel befasst sich mit der Lösung von vier Segmentierungsproblemen, wovon die ersten zwei (in diskretisierter Form) global und mittels kombinatorischer Verfahren optimiert werden. Die folgenden zwei (bewegungsbasierten) Probleme sind schwerer zu lösen. Hier werden lokale Minima durch die Alternierung diskreter und kontinuierlicher Verfahren gefunden.

Die vorgestellten Ansätze wurden im Rahmen der Doktorarbeit des Autors [Sch09] und in enger Zusammenarbeit mit Daniel Cremers entwickelt. Alle relevanten eigenen Publikationen, sowie Details zur Notation und die originalen Bilddaten, sind dort zu finden.

2 Krümmungsbasierte Bildsegmentierung

Unser erstes Problem behandelt die vollautomatische Segmentierung eines einzelnen Graustufenbildes $I : \Omega \rightarrow \mathbb{R}$, wobei wir einen kantenbasierten Ansatz verfolgen, der eine einzelne zusammenhängende Vordergrundregion findet. Anstelle einer Funktion $l : \Omega \rightarrow \{1, 2\}$ suchen wir eine stetige Konturlinie $C : \mathbb{S}^1 \rightarrow \Omega$ (wobei \mathbb{S}^1 den Einheitskreis bezeichnet), deren Inneres die Vordergrundregion beschreibt.

Anforderungen. Bei konturbasierten Ansätzen gilt es drei Probleme zu lösen: zunächst gilt es, eine Kostenfunktion zu finden, deren Optima weder unendlich großen noch infinitesimal kleinen Regionen/Regionskonturen entsprechen. Anschließend muss sichergestellt werden, dass auch Konturen mit teilweise schwachem Kontrast als Objektgrenzen möglich werden. Schlussendlich möchte man nur über Konturlinien minimieren, die sich nicht selbst schneiden, da nur diese sinnvolle Segmentierungen definieren.

Eine Lösung für das erste Problem wurde in [JI01] präsentiert und dient als Basis unseres Ansatzes. Das zweite Problem behandeln wir mittels des Konzeptes der *Krümmungsregularisierung*. Ein verwandter Ansatz wurde in [AWJ90] vorgestellt. Jedoch verwenden wir ein ausgefeiltere Kostenfunktion und erreichen, dank des Prinzips der Ratio-Minimierung, eine effektiv deutlich bessere Laufzeit.

Das dritte Problem, das Ausschließen von Selbstschnitten, bleibt in diesem Ansatz unbehandelt. In der Praxis treten Selbstschnitte so selten auf, dass für eine Vielzahl von Bildern

sinnvolle Regionen gefunden werden und zugleich die Qualität des vorgeschlagenen (diskretisierten) Modelles beurteilt werden kann : da der Algorithmus in diesen Fällen das globale Optimum findet, müssen ungewollte Lösungen durch das Modell selbst verursacht worden sein.

Nach Abgabe der Dissertation publizierte der Autor, in enger Zusammenarbeit mit Daniel Cremers und Fredrik Kahl, einen regionsbasierten Ansatz [SKC09] mit Krümmungsregularisierung, der Selbstschnitte ausschließt, mehrere Regionen finden kann und auch Benutzerinteraktion erlaubt.

Mathematische Beschreibung. Um unseren Ansatz zu beschreiben, müssen zunächst einige Symbole eingeführt werden. Mit Ausnahme des Bildgradienten ∇I und des Gewichtungsparmeters λ beziehen sich alle Symbole auf Eigenschaften der Kontur C . So bezeichnet $C_t(t)$ den Vektor der partiellen ersten Ableitungen von C an der Stelle $C(t)$. Der Normalenvektor $n_C(t)$ an der Stelle $C(t)$ steht senkrecht zum Ableitungsvektor und hat eine Länge von 1. Schließlich bezeichnet $\kappa_C(t)$ die Krümmung von C an der Stelle $C(t)$.

Unsere Kostenfunktion ist gebrochen rational und minimiert ein kantenbasiertes Linienintegral über eine gewichtete Summe der Konturlänge und dem Integral der quadrierten Krümmung entlang der Kontur:

$$\min_C \frac{\int_{S^1} \nabla I(C(t)) \cdot n_C(t) |C_t(t)| dt}{\int_{S^1} [\lambda + |\kappa_C(t)|^2] |C_t(t)| dt} . \tag{1}$$

Tatsächlich kann der vorgestellte Ansatz eine noch generellere Klasse von Funktionen minimieren [Sch09]. Eine Besonderheit des Ansatzes ist, dass jede Kontur doppelt repräsentiert wird, da sie in zwei Richtungen durchlaufen werden kann. Ändert man die Richtung, so ändern auch alle Normalenvektoren ihr Vorzeichen. Folglich ändert der gesamte Zählerterm sein Vorzeichen und da wir nur an der Konturlinie, nicht aber ihrer Durchlaufrichtung interessiert sind, wird das Funktional effektiv maximiert.

Der Zähler bevorzugt Konturen deren Normalen parallel zum Bildgradienten stehen und damit den Kanten des Bildes entsprechen. Der Krümmungsterm im Nenner bevorzugt längere Kurven ohne scharfe Richtungsänderungen. Das Längengewicht λ schließlich zieht die Konturen zurück zu den Bildkanten.

Wir lösen eine diskretisierte Version des Problems (1), wobei wir uns auf polygonale Konturen beschränken, die aus einer gegebenen Menge von Liniensegmenten zusammengesetzt werden. Diese entstehen, indem wir die Pixel des Bildes mit allen Pixeln in einem bestimmten Umkreis verbinden.

Das entstehende Problem kann nun als Minimierung über Kreise in einem Graphen formuliert werden, wobei ein ähnlicher Graph wie in [AWJ90] eingesetzt wird. Dabei greifen wir auf die Technik der Ratiominimierung zurück, die in der hier relevanten Form in [Law66] aufgezeigt wurde. Hierbei hat man eine Funktion der Form

$$E(C) = \frac{\sum_{e \in C} n(e)}{\sum_{e \in C} d(e)} ,$$



Abbildung 1: Das krümmungsbasierte Modell führt zu sinnvolleren Regionen als ein rein längenbasiertes Modell [JI01].

wobei C ein Kreis im Graphen ist, e Kanten im Kreis bezeichnet, $n(e)$ beliebige Zählergewichte und $d(e)$ nicht-negative Nennergewichte sind (wobei der Nenner niemals 0 werden darf). Die fundamentale Beobachtung ist nun folgende Äquivalenz (die nur für nicht-negative Nennergewichte gilt). Wenn τ eine beliebige Ratio ist und C ein Kreis mit besserer Ratio, so gilt:

$$\begin{aligned} \frac{\sum_{e \in C} n(e)}{\sum_{e \in C} d(e)} &< \tau \\ \Leftrightarrow \sum_{e \in C} n(e) &< \tau \sum_{e \in C} d(e) \\ \Leftrightarrow \sum_{e \in C} [n(e) - \tau d(e)] &< 0 \end{aligned}$$

Folglich gibt es einen Kreis mit besserer Ratio als τ genau dann wenn im Graphen ein negativer Kreis bezüglich der Kantengewichte $n(e) - \tau d(e)$ existiert. Solche negativen Kreise lassen sich mit Hilfe des Moore-Bellman-Ford Algorithmus für Distanzberechnungen finden. Die Suche nach dem besten τ kann nun iterativ vollzogen werden, wobei jedes Mal, wenn ein negativer Kreis gefunden wird, τ auf dessen Ratio gesetzt wird.

Experimente Ein Vergleich zwischen dem vorgeschlagenen Modell (1) und dem als Basis dienenden Ansatz [JI01] ist in Abbildung 1 gegeben. Er zeigt, dass letzterer einen hohen Kontrast entlang der gesamten Kontur benötigt, was regelmäßig zu sehr kurzen Konturen führt. Dies wird durch den Krümmungsterm behoben.

3 Integration von Formenwissen

Auch unser zweiter Ansatz behandelt die Segmentierung von Einzelbildern in eine einzelne, zusammenhängende Vordergrundregion und Hintergrund, jedoch ist diesmal Vorwissen in Form einer Kontur $\mathbf{S} : \mathbb{S} \rightarrow \Omega$ gegeben (vgl. Abb. 2, links). Die gesuchte Kontur $\mathbf{C} : \mathbb{S} \rightarrow \Omega$ soll ähnlich zu \mathbf{S} sein, im Allgemeinen jedoch nicht identisch. Das bedeutet, dass wir Deformationen zulassen, diese jedoch mit Kosten bestrafen. Dazu wird ein

Matching von S auf jede erdenkliche Kontur C berechnet und schließlich die global beste Kontur C ermittelt. Unser Ansatz ist translationsinvariant und lässt sich auf die Behandlung lokaler und globaler Rotationen erweitern.

Modell. Wie im vorigen Abschnitt verwenden wir eine gebrochen rationale Kostenfunktion, die diesmal aus drei Termen besteht. Der erste Term zieht die Kontur auf die Bildkanten. Der zweite vergleicht die Tangentenwinkel der beiden Konturen an den Stellen, die das Matching als zusammengehörig identifiziert. Der dritte schließlich bestraft lokale Streckungen und Stauchungen, die durch das Matching entstehen.

Auch wenn wir das Modell im Folgenden nur kurz erläutern, müssen wir doch ein wenig Notation einführen. Das Symbol $\alpha_C(t)$ bezeichnet den Winkel zwischen der Tangente der Kontur C an der Stelle $C(t)$ und einer horizontalen Linie. Gleiches gilt für $\alpha_S(t)$ und S . Um die Differenz zweier Winkel zu berechnen muss ihre zyklische Natur berücksichtigt werden, d.h. $|\alpha_C - \alpha_S|_{\mathbb{S}^1}$ bezeichnet die Distanz auf der Mannigfaltigkeit \mathbb{S}^1 . Ferner benötigen wir eine Matchingfunktion $m : \mathbb{S}^1 \rightarrow \mathbb{S}^1$, die Punkte $C(t)$ auf C mit Punkten $S(m(t))$ auf S in Verbindung bringt. Lokale Streckungen und Stauchungen sind daran zu erkennen, dass die erste Ableitung von m von einem bestimmten Wert abweicht. Diese Abweichungen werden durch eine (in [Sch09] beschriebene) Funktion $\Psi(\cdot)$ bestraft. Mit einem Kantendetektor

$$g(\mathbf{x}) = (1 + |\nabla I(\mathbf{x})|)^{-1}$$

können wir schließlich das Modell wie folgt spezifizieren:

$$\min_C \frac{\int_{\mathbb{S}^1} g(C(t)) |C_t(t)| dt}{\|C\|} + \frac{\int_{\mathbb{S}^1} |\alpha_C(t) - \alpha_S(m(t))|_{\mathbb{S}^1} |C_t(t)| dt}{\|C\|} + \frac{\int_{\mathbb{S}^1} \Psi\left(\frac{\|S\|m_t(t)}{\|C\|}\right) |C_t(t)| dt}{\|C\|} .$$

Methodik. Erneut diskretisieren wir das kontinuierliche Problem, indem wir die Konturen auf polygonale Kantenzüge einschränken. Das entstehende Problem lässt sich wiederum als globale Optimierung über eine gewisse Klasse von Kreisen in einem Graphen formulieren, wobei der Graph diesmal eine deutlich andere Struktur hat, wie in Abbildung 2 dargestellt.

Für jeden Punkt entlang der vorgegebenen Kontur S enthält der Graph eine Kopie (oder sogar mehrere) des Eingabebildes, wobei benachbarte Punkte auch benachbarten Kopien entsprechen. Da die Kontur geschlossen ist, besitzt der Graph die Topologie eines Torus. Wir optimieren nun über zyklische Pfade im Graphen, die sich genau einmal um das Loch im Inneren winden. Die Stelle, an der der Pfad eine Kopie des Bildes schneidet, gibt uns die Position, an der der entsprechende Punkt auf S im Ursprungsbild sichtbar wird.

Die eigentliche globale Optimierung ist der aus dem vorherigen Abschnitt recht ähnlich. Da jedoch nicht alle Kreise gültigen zyklischen Pfaden entsprechen muss zusätzlich noch




Abbildung 2: Konturoptimierung als Optimierung über zyklische Pfade in einem Produktgraphen

ein Branch-und-Bound ausgeführt werden. Weiterhin erlaubt die spezielle Struktur des Graphen hocheffiziente Parallelisierungen auf moderner Grafikkhardware.

Verwandte Arbeiten. Die unserem Ansatz ähnlichste Arbeit ist [CYES01], wo eine offene Kontur auf ein Bild gematcht wird. Es gibt im wesentlichen zwei Unterschiede zum vorgestellten Ansatz: zum einen verwenden wir eine gebrochen-rationale Kostenfunktion, die wie in [SSC08] gezeigt bei Regionen schwachen Kontrastes das bessere Modell ist. Zum anderen behandeln wir das schwierigere Problem geschlossener Konturen. Hierbei ist das Prinzip der Ratiominimierung im Allgemeinen robuster als der in [SSC08] vorgestellte Ansatz mit Branch-und-Bound für Linienintegrale.

Erweiterungen. Der vorgestellte Ansatz kann leicht auf verwandte Probleme erweitert werden. Zunächst kann man auch das Problem des Trackings deformierbarer Objekte behandeln. Weiterhin kann zusätzlich ein Sampling über eine globale Rotation durchgeführt werden.

Schließlich lassen sich auch *lokale* Rotationen behandeln, indem man statt eines 3D-Produktgraphen einen 4D-Graphen verwendet. In diesem Fall braucht man allerdings einen stärkeren Datenterm, der zusätzlich zur eingegebenen Kontur auch eine Textur in ihrem Inneren bekommt.

Experimente. Eine Auswahl an Experimenten ist in Abbildung 3 gegeben, wobei die rote Kontur als Eingabe für das linke Bild dient. In Gegenwart von Rotationen müssen diese tatsächlich mitmodelliert werden.




Abbildung 3: Der vorgeschlagene Ansatz erlaubt signifikante Deformationen der gegebenen Kontur.

4 Bewegungssegmentierung

In den verbleibenden zwei Problemen beschäftigen wir uns mit der Segmentierung von Videos, indem wir gleichzeitig die Bewegung im Video mitschätzen. Die entstehenden Probleme werden nun nicht mehr global, sondern lokal minimiert.

In diesem Abschnitt behandeln wir zunächst das Problem der Bewegungssegmentierung. Gegeben zwei Bilder I_1 und I_2 ist es hier die Aufgabe, die Bewegung der Pixel in I_1 zu bestimmen und gleichzeitig I_1 in zwei Regionen zu segmentieren. Wir nehmen zunächst an, dass sich alle Pixel in Region 1 anhand einer Normalverteilung mit mittlerer Geschwindigkeit \mathbf{v}_1 und gepoolter Varianz σ_1^2 bewegen, und analog für Region 2 und \mathbf{v}_2/σ_2^2 . Unter den Definitionen

$$\nabla I(\mathbf{x}) = \frac{1}{2}(\nabla I_1(\mathbf{x}) + \nabla I_2(\mathbf{x}))$$

$$I_t(\mathbf{x}) = I_2(\mathbf{x}) - I_1(\mathbf{x})$$

lässt sich folgendes Funktional herleiten [Sch09]:

$$\min_{\{R_i\}, \{\mathbf{v}_i\}, \{\sigma_i\}} \sum_{i=1}^2 \int_{R_i} \left(\log(\sigma_i) + \left(\frac{I_t(\mathbf{x}) + \nabla I(\mathbf{x})^T \mathbf{v}_i}{\sigma_i |\nabla I(\mathbf{x})|} \right)^2 \right) dx + \nu |\partial R_i| .$$

Wir berechnen lokale Minima dieses Problems mittels des Prinzips der alternierenden Minimierung, wobei iterativ die Regionen, die Geschwindigkeiten und die Standardabweichungen σ_i neu berechnet werden - auf Basis der jeweils aktuellen Werte der anderen Parameter.

Die Unterprobleme werden jeweils global gelöst, sodass der Ansatz schnell konvergiert. Für die Optimierung der Regionen wird der schnelle Graph Min-Cut Algorithmus [BK04] verwendet, für die anderen beiden Probleme werden jeweils kleine lineare Gleichungssysteme gelöst.

In einem erweiterten Ansatz setzen wir auch komplexere Bewegungsmodelle wie ein affines und ein quadratisches ein.

Verwandte Arbeiten. Ein ähnlicher stochastischer Ansatz wurde in [CY03] verwendet, wobei aber die Varianz festgesetzt und ein lokales und kontinuierliches Segmentierungsverfahren verwendet wurde. Für weitere Arbeiten zur Bewegungssegmentierung siehe [Sch09].



Abbildung 4: Bewegungssegmentierung für Bildpaare

Experimente. Abbildung 4 demonstriert unseren Ansatz auf der bekannten Coastguard Sequenz¹: ausgehend von einer sehr groben Initialisierung wird eine akkurate Segmentierung sowie ein gutes Bewegungsmodell berechnet. Hierbei verwenden wir eine Farbkodierung der Bewegungsvektoren, wobei der Farbton die Richtung und die Saturierung die Stärke der Bewegung darstellen.

Ein zentrales Ziel unserer Arbeit war es, längere Videosequenzen (nach einer Initialisierungsphase) in Echtzeit behandeln zu können. Auf Auslösungen von 160×120 gelingt dies bereits, bei 360×240 Pixeln werden immerhin 17 Frames pro Sekunde erreicht.

5 Layerzerlegung

Beim letzten Ansatz handelt es sich um ein sehr umfangreiches Projekt, auf das aus Platzgründen nur kurz eingegangen wird. Aus diesem Grund verzichten wir auch auf eine ausführliche Beschreibung des Modells und verweisen auf [Sch09], auch für eine Einordnung des Beitrages.

Im vorherigen Abschnitt wurde sowohl ein Video segmentiert als auch seine Bewegung geschätzt. Jedoch wird in der Praxis nicht die exakte Regionengrenze gefunden, da ein wichtiger Punkt nicht mitmodelliert wird: einige Pixel sind im nächsten Bild nicht zu sehen, da sie *verdeckt* werden. Weiterhin bekommen wir zwar eine Segmentierung, aber keinerlei Aufschluss über das Aussehen der Objekte in der Szene.

Der Ansatz der Layerzerlegung löst das erste Problem und macht einen wichtigen Schritt zur Lösung des zweiten: er modelliert das Video als eine Überlagerung planarer Objekte, sogenannter Layer. Dabei gilt es, sowohl die Form als auch das Aussehen (Textur) und die Bewegung der Layer zu bestimmen; ihre Anzahl nehmen wir als bekannt an.

Das Modell [Sch09, Seite 102] besteht aus einem Datenterm, der Layerintensitäten mit den entsprechenden Positionen im Video vergleicht (quadrierte Differenzen), und zwei Regularisierungstermen, die die Länge der Layergrenzen sowie deren Intensitäten beeinflussen. Es kann als Kosten für die Kodierung des Videos interpretiert werden.

Um lokale Optima zu finden setzen wir abermals das Prinzip der alternierenden Minimierung ein, wobei wir die Form der Layer mittels eines Graph Min-Cuts bestimmen. Das

¹<http://trace.eas.asu.edu/yuv/index.html>



Abbildung 5: Zerlegung einer 30-Bilder Sequenz in drei Layer



Abbildung 6: Für scharfe Layerbilder müssen Details des Bildformierungsprozesses modelliert werden.

Bewegungsmodell und auch die Layerintensitäten werden durch kontinuierlicher Verfahren optimiert, zunächst unter Annahme eines parametrischen Bewegungsmodells.

In einem zweiten Schritt setzen wir ein detailliertes Kameramodell ein, dass auch die Linsenverzerrung und die Mittelung von Pixeln über eine bestimmte Fläche mitberücksichtigt. Wir lassen nun auch eine nichtparametrische Bewegungskomponente zu [HS81] und wechseln zu einem robusten Datenterm. Abbildung 6 zeigt den Effekt dieser Änderungen, Abbildung 5 zeigt die berechnete Layerzerlegung für die bekannte Flower Garden Sequenz.

6 Schlusswort

Diese Arbeit hat eine Vielzahl von Segmentierungsproblemen für Bilder und Videos adressiert, wobei verstärkt kombinatorische Verfahren eingesetzt wurden. Wir haben einen strengen modellbasierten Ansatz verfolgt und wo immer möglich nach globalen Optima gesucht. Die Arbeit ist weiterhin eng verwandt mit den Problemen der Bewegungsschätzung, des Trackings, der Bildentrauschung und der Super-Resolution.

Literatur

- [AWJ90] A.A. Amini, T.E. Weymouth und R.C. Jain. Using dynamic programming for solving variational problems in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 12(9):855–867, September 1990.
- [BK04] Y. Boykov und V.N. Kolmogorov. An experimental comparison of min-cut/max-flow

- algorithms for energy minimization in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 26(9):1124–1137, 2004.
- [BT99] S. Birchfield und C. Tomasi. Multiway cut for stereo and motion with slanted surfaces. In *IEEE International Conference on Computer Vision (ICCV)*, Korfu, Griechenland, September 1999.
- [CY03] D. Cremers und A.L. Yuille. A generative model-based approach to motion segmentation. In *Pattern Recognition (Proc. DAGM)*, Magdeburg, Deutschland, September 2003.
- [CYES01] J. Coughlan, A. Yuille, C. English und D. Snow. Efficient deformable template detection and localization without user initialization. *Computer Vision and Image Understanding*, 78(3):303–319, 2001.
- [HS81] B.K.P. Horn und B.G. Schunck. Determining optical flow. *Artificial Intelligence*, 17:185–203, 1981.
- [JF01] N. Jovic und B. Frey. Learning flexible sprites in video layers. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, Kauai Marriott, Hawaii, Juni 2001.
- [JI01] I.H. Jermyn und H. Ishikawa. Globally optimal regions and boundaries as minimum ratio weight cycles. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)*, 23(10):1075–1088, 2001.
- [Law66] E.L. Lawler. Optimal cycles in doubly weighted graphs. In *Theory of Graphs: International Symposium*, Seiten 209–213, New York, New York, 1966. Gordon and Breach.
- [MS89] D. Mumford und J. Shah. Optimal approximations by piecewise smooth functions and associated variational problems. *Communications on Pure and Applied Mathematics*, 42:577–685, 1989.
- [Sch09] T. Schoenemann. Combinatorial solutions for shape optimization in computer vision, Dissertation an der Universität Bonn, April 2009.
- [SKC09] T. Schoenemann, F. Kahl und D. Cremers. Curvature regularity for region-based image segmentation and inpainting: A linear programming relaxation. In *IEEE International Conference on Computer Vision (ICCV)*, Kyoto, Japan, September 2009.
- [SSC08] T. Schoenemann, F.R. Schmidt und D. Cremers. Image segmentation with elastic shape priors via global geodesics in product spaces. In *British Machine Vision Conference (BMVC)*, Leeds, U.K., September 2008.



Thomas Schoenemann wurde am 10. Dezember 1979 in Münster, Westfalen, geboren, wo er bis zum 10. Lebensjahr lebte. Anschließend besuchte er das Gymnasium Korschenbroich (bei Düsseldorf) und studierte schließlich Informatik an der RWTH Aachen. Nach einer Diplomarbeit im Bereich der probabilistischen Übersetzung natürlicher Sprache erhielt er Ende 2005 sein Diplom und wechselte an die Universität Bonn, um eine Doktorarbeit im Gebiet des Maschinensehens zu beginnen. Diese gab er Ende 2008 ab und erhielt schließlich im April 2009 den Titel Dr. rer. nat. Er hat auf hochangesehenen internationalen Konferenzen publiziert, für die er auch regelmäßige Reviews schreibt. 2008 erhielt er den Best Student Reviewer Award der Konferenz CVPR.