

# Methodik zur Segmentierung organischer Objekte einer gleichartigen Gruppe in Farbbildern

Enrico Gutzeit, Uwe von Lukas

Fraunhofer-Institut für Graphische Datenverarbeitung IGD,  
Joachim-Jungius-Straße 11, D-18059 Rostock  
eMail: {enrico.gutzeit, uwe.von.lukas}@igd-r.fraunhofer.de  
URL: <http://www.igd-r.fraunhofer.de>

**Zusammenfassung.** Die Segmentierung ist ein breites Forschungsfeld mit einer Vielzahl an Methoden. Viele Methoden der Segmentierung ermöglichen eine Segmentierung von Objekten. Allerdings müssen i.d.R. zur robusten Segmentierung gewisse Rahmenbedingungen in der Bildaufnahme eingehalten werden, wie bspw. ein homogener Hintergrund und eine gleichmäßige Ausleuchtung. In diesem Beitrag wird eine Methodik erarbeitet zur automatischen Segmentierung von organischen Objekten einer gleichartigen Gruppe, wie Äpfel und Fische. Die Methodik ermöglicht verschiedene Anwendungen, benötigt wenige Restriktionen in der Bildaufnahme und extrahiert pro Bild die benötigten Informationen zur Segmentierung. Die Grundannahme ist, dass sich pro Bild gleichartige organische Objekte ähnlich sind. Hingegen in verschiedenen Bildern die Objekte unterschiedlich sind infolge der variierenden Beleuchtungseinflüsse. Die Methodik wird diskutiert, die einzelnen Schritte aufgezeigt und erste Ergebnisse präsentiert.

## 1 Einleitung

Die Segmentierung von Objekten in Farbbildern ist mit den unterschiedlichsten Methoden möglich. Die richtige Auswahl und Adaption der Methode ist abhängig von der Anwendung und den Rahmenbedingungen. So lassen sich bspw. Münzen in einem Bild durch eine Kreisfindung (z.B. Hough-Transformation) oder helle Objekte auf einem homogenen dunklen Hintergrund mit einem Schwellwertverfahren (z.B. Otsu's Methode [34]) einfach segmentieren. Variieren die Objekte und die Rahmenbedingungen, ist die Segmentierung eine herausfordernde Aufgabe. In diesem Beitrag wird für eine spezielle Klasse von Anwendungen unter den verschiedensten Rahmenbedingungen eine Methodik erarbeitet. Die Methodik dient zur Segmentierung von organischen Objekten einer gleichartigen Gruppe in Farbbildern. Eine solche Gruppe wird in diesem Beitrag mit organo-Gruppe abgekürzt. Beispiele von organo-Gruppen sind Fische, Äpfel, Hühner und die Schnittflächen von Baumstämmen. Praktische Relevanz hat die Segmentierung einer organo-Gruppe in der Vermessung, der Qualitätskontrolle oder der automatischen Zählung. Konkrete Beispiele sind das Monitoring von Fischen in der Aquakultur, die automatische Ernte von Früchten und die Vermessung von Baumstämmen. Die Methodik wird aufbauend auf unseren bisherigen Arbeiten zur automatischen Segmentierung von Stammschnittflächen entwickelt. Es wird gezeigt, wie sich das Verfahren, das für eine besondere Gruppe organischer Objekte entwickelt wurde, auf andere Gruppen übertragen lässt und

welche Teilprobleme dafür zu lösen sind. Die Ergebnisse werden präsentiert und diskutiert. Die Methodik basiert auf der Detektion einiger Objekte der Gruppe anhand eines Detektors, der Extraktion von Informationen und der Nutzung zur Segmentierung. Die Grundannahme besteht darin, dass sich die Objekte in einem Bild in Form, Farbe und/oder Textur ähnlich sind. Ausgehend vom aktuellem Stand und unseren bisherigen Arbeiten im Bereich der automatischen Segmentierung von Stammschnittflächen wird nachfolgend eine erste generelle Methodik zur Segmentierung von organo-Gruppen vorgestellt.

## 2 Stand der Forschung zur Segmentierung

Die Segmentierung einer organo-Gruppe ist eine spezifische Fragestellung und in der Forschung nur partiell adressiert. Wissenschaftliche Beiträge sind zumeist für eine spezielle organo-Gruppe ausgelegt, wie für Äpfel, Fische oder Stammschnittflächen. Die Beiträge enthalten folglich **spezielle Methoden**, die auf die Anwendung zugeschnitten sind. Die speziellen Methoden adaptieren und kombinieren die verschiedensten **Basismethoden**.

Die Basismethoden der Segmentierung zerlegen ein Bild in disjunkte Pixelmengen, den sogenannten Segmenten. Es existieren enorm viele Basismethoden der Segmentierung und stetig werden neue veröffentlicht. Das Forschungsfeld der Segmentierung ist enorm breit [4]. Beiträge und Bücher zur Segmentierung betrachten die Segmentierung aus unterschiedlichen Blickwinkeln, wodurch es die verschiedensten Klassifikationen der Methoden gibt. Abgeleitet aus den Büchern [1]-[8] lassen sich die Algorithmen in Objektdetektion und pixel-, kontur-, regionen- und optimierungsbasierte Segmentierungsmethoden einteilen (siehe Abb. 1).

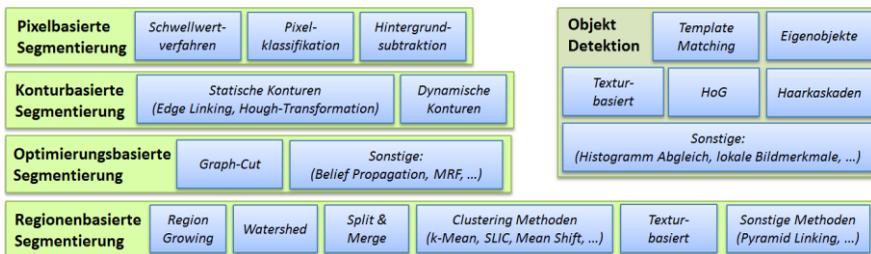


Abb. 1. Eigene Klassifikation der wesentlichen Segmentierungsansätze

Die pixelbasierten Methoden, wie Schwellwertverfahren [9], ordnen jedem Pixel, unabhängig von den benachbarten Pixeln, ein Label zu. Die konturbasierten Methoden, wie aktive Konturen [10][11], operieren auf Bildkanten oder Gradienten und ermitteln Konturen. Alles was von der Kontur eingeschlossen wird, entspricht dem gesuchten Segment. Die regionenbasierten Methoden zerlegen ein Bild in Segmente gleicher Eigenschaften. Sie stellen die größte Methodenklasse der Segmentierung dar und sind in der Methodik der Segmentierung sehr verschieden. Beispiele sind Watershed [12], Split & Merge [13] oder Methoden des Clustering, wie Mean Shift [14]. Die optimierungsbasierten Methoden optimieren die Segmentierung eines bereits segmentierten Bildes oder segmentieren ein Bild anhand von Vorwissen. In diese Klasse lassen sich Graph-Cut [15] und Normalized Cut [16] einordnen. Die Objektdetektion detektiert Objekte durch ein Modell. Es wird i.d.R. im Bild oder einer Transformation des Bildes gesucht und mit dem

Model abgeglichen, wie mit Haarkaskaden [17] und Template Matching [18].

Im Gegensatz zu den von der Anwendung unabhängigen Basismethoden sind die speziellen Methoden abhängig von der Anwendung. Bei der Segmentierung von organo-Gruppen gibt es relativ wenige Beiträge. Ein Teil der Beiträge wird nachfolgend beschrieben und den Basismethoden zugeordnet.

Die **Segmentierung von Stammschnittflächen** ist Thema in [19][20][21] und [22]. In [19] werden Watershed und aktive Konturen adaptiert und in [20] wird ein globales Schwellwertverfahren mit Nutzerinteraktion angewandt. In [21] wurde ein iterativer Graph-Cut zur Segmentierung der Stämme eines im Bild zentrierten Holzpolters entwickelt. In [22] wird das Verfahren erweitert und mit Haarkaskaden kombiniert, so dass der Holzpolter irgendwo im Bild sein kann.

Die **Segmentierung von Äpfeln** wird in [23]-[27] adressiert. In [23][24] und [25] werden Methoden der Objektdetektion kombiniert und angepasst. In den drei Beiträgen werden die Äpfel texturbasiert durch Merkmale der GLCM (Grey Level Co-Occurrence Matrix) segmentiert oder detektiert. In [23] werden anhand der GLCM Schwellwerte bestimmt, wodurch das Grauwertbild auf 20 Werte abgebildet wird. Das Resultat wird anschließend durch eine Maske und spezieller Regeln in ein Binärbild umgewandelt (0 oder 255). In [24] wird das Bild auf 16 Werte quantisiert, der Kontrast der lokalen GLCM ermittelt und geschlossene Konturen auf dem Kontrastbild gesucht. In [25] wird der Hue Kanal des HSV Farbraumes in 8x8 Blöcke zerlegt. Pro Block wird die Energie der GLCM bestimmt. Anhand eines zuvor erstellten Modells EM (Expectation Maximization) wird das Bild für Äpfel und Hintergrund segmentiert. In [26] wird die Detektion von Granatäpfeln anhand eines speziellen Farbraumes vorgenommen. Von den im Beitrag untersuchten Farbräumen erweist sich die modifizierte Differenz  $mR-mG$  und  $mR-mB$  als geeignet zur Segmentierung. In [27] wird ein mehrstufiger Ansatz vorgestellt. Die Pixel werden zunächst mit KNN klassifiziert. Anschließend werden benachbarte ähnliche Pixel zu Segmenten zusammengefügt. Danach werden die Segmente in Bogensektionen und Sonstiges zerlegt und abschließend zu kreisähnlichen Objekten gruppiert.

Die **Segmentierung von weiteren Früchten** wird in [28][29] und [30] adressiert. In [28] werden Zitronen mittels einer Pixelklassifikation durch einen Bayes-Klassifikator segmentiert. In [29] werden Kiwis segmentiert. Es werden zuerst die RGB-Kanäle speziell transformiert und das Bild in den Lab Farbraum konvertiert. Peaks im Histogramm der a und b Komponenten werden in Form von Clustern angelernt. Anhand des Abstandes zu den Clustern wird das Bild segmentiert. Die Segmentierung von Kirschen unter kontrollierten Bedingungen auf homogenen Hintergrund wird in [30] adressiert. Die Segmentierung arbeitet grob in drei Schritten. Zuerst werden Cluster mit Fuzzy C-Mean (FCM) im RGB-Farbraum erstellt. Von den Clustern werden sieben dem Vordergrund und drei dem Hintergrund zugeordnet. Die Zuordnung der Cluster wurde zuvor anhand der Grundwahrheit experimental ermittelt. Die Vordergrund-Cluster werden im finalen Schritt als Ausgangspunkt für Fuzzy Aktive Konturen genutzt.

Die **Segmentierung von Fischen** ist teilweise Thema in [31] und [32]. In [31] wird eine Kombination aus mean-shift und median-cut zur Segmentierung von Fischen vorgestellt. Die Farbe wird erst mit einer Histogramm-Equalisierung korrigiert. Anschließend wird eine mean-shift-Segmentierung im LUV-Farbraum durchgeführt und die Farbe mittels median-cut quantisiert. Nach einer Kantendetektion im Ergebnisbild sind einzelne Fische von einer Kontur umschlossen. Das Problem der Einzelbildsegmentierung wird in [32] umgangen und die Bild-zu-Bild Kohärenz in Videos mit Hilfe von Hintergrundsubtraktion genutzt.

### 3 Problemdiskussion

Das Ziel ist die automatische Segmentierung einer organo-Gruppe. Eine organo-Gruppe ist eine Menge von gleichartigen organischen Objekten. Vorausgesetzt wird, dass die Objekte der Gruppe organisch sind und sich in Form, Farbe und Textur ähnlich sind. Weiterhin soll von einer natürlichen Umgebung (Outdoor) ausgegangen werden. Beispiele von organo-Gruppen sind in Abb. 1 zu sehen.



**Abb. 1.** Verschiedene organo-Gruppen (Links: Stammschnittflächen eines Holzpolter, Mitte: Äpfel am Baum und am Boden, Rechts: Fische unter Wasser).

Der dargelegte aktuelle Stand der Forschung zeigt, dass die existierenden Ansätze sehr verschieden sind. Bisherige spezielle Methoden adaptieren und kombinieren die verschiedensten Basismethoden. Darüber hinaus sind die speziellen Methoden für spezielle organo-Gruppen unter speziellen Rahmenbedingungen angedacht. Bisher existiert noch keine generelle Lösung für das Problem.

Die Segmentierung von organo-Gruppen bringt viele Herausforderungen und Probleme mit sich:

- Objekte unbekannter Form, Farbe und Textur
- Hintergrund (nicht Objektpixel) unbekannter Farbe und Textur
- Varianzen in Farbe, Form und Textur innerhalb der Objektklasse
- Varianzen in Farbe und Textur im Hintergrund
- Überschneidung der Farbbereiche vom Hintergrund mit den Objekten

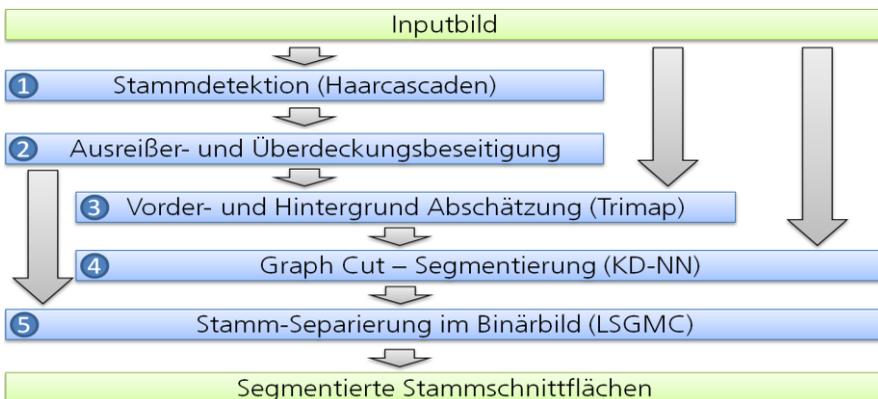
Das Konzept einer speziellen Segmentierungsmethode und die Entscheidung für die zu adaptierenden Basismethoden ist prinzipiell immer abhängig vom Vorwissen über das Bild und dem Ziel der Segmentierung. Zur Lösung der genannten Probleme können im Fall der Segmentierung von organo-Gruppen lediglich folgende Annahmen getroffen werden:

- Mehrere ähnliche organische Objekte in einem Bild
- Objekte haben ähnliche Eigenschaften

### 4 Unsere Methodik zur Segmentierung von Stammschnittflächen

Eine Klasse von organischen Objekten einer gleichartigen Gruppe sind die Schnittflächen von Baumstämmen in einem Bild, welche aufgestapelt Holzpolter genannt werden (siehe Abb. 1 - links). In unseren bisherigen Arbeiten (siehe [21] und [22]) ist eine Methodik zur automatischen Segmentierung der

Stammschnittflächen entwickelt worden. Die Methodik untergliedert sich in fünf Schritte, welche in Abb. 2. verdeutlicht sind.



**Abb. 2.** Methodik zur Segmentierung von Stammschnittflächen eines Holzpolters.

Zuerst werden die Schnittflächen mit Haarkascaden [17] detektiert, Ausreißer entfernt und Überdeckungen beseitigt. Von den verbleibenden Stämmen wird der Schwerpunkt ermittelt und die 50% dichtesten zur Vordergrundabschätzung weiter genutzt. Da sich zwischen den Stämmen Schatten befinden, führt eine Segmentierung mit der Otsu's Methode [34] zu einer Segmentierung von ersten Holzpixeln, die den Vordergrund darstellen. Der Hintergrund ergibt sich aus einer Schwellwertsegmentierung des inversen Distanzbildes vom Binärbild der verifizierten Objekte. Aus Vorder- und Hintergrund und den noch nicht zugeordneten unbekanntenen Pixeln wird eine Trimap erstellt. Aus der Trimap wird je ein Vorder- und Hintergrundmodell in Form eines KD-Baumes erstellt. Anhand einer Dichteabschätzung (KD-NN) im KD-Baum und der Gradienten im Bild werden die Gewichte eines Graphen gesetzt. Eine anschließende Segmentierung mit Graph-Cut führt zu einem Binärbild (Holz, nicht Holzpixel). Das Segmentierungsergebnis wird mit den detektierten Stämmen überlagert und die Objekte anhand wachsender bewegender Maxima separiert (LSGMC). Eine Evaluierung mit 71 sehr verschiedenen Bildern führte zu einem f-score von 0.91 (Ein Wert von 1 entspricht einer perfekten Segmentierung).

## 5 Abgeleitete Methodik zur Segmentierung von organo-Gruppen

Der Grundgedanke der Segmentierung von Stammschnittflächen ist die Nutzung einer groben Objektdetektion und die Segmentierung mit Graph-Cut anhand der aus dem Bild extrahierten Vorder- und Hintergrundinformationen. Das prinzipielle Vorgehen ist übertragbar und generalisiert in Abb. 3 illustriert. Es ergeben sich wieder fünf Schritte, die allerdings angepasst und generalisiert werden müssen. Im ersten Schritt werden die Objekte anhand eines trainierten Detektors detektiert. In einem zweiten Schritt werden falsch detektierte Objekte verworfen. Anhand der verifizierten Objekte wird im dritten Schritt ein Vorder- und Hintergrundmodell erstellt. Die Modelle und die verifizierten Objekte werden im vierten Schritt zur optimierungsbasierten Segmentierung genutzt. Das Ergebnis ist ein Binärbild bestehend aus Objekt und nicht Objektpixel. Das Binärbild und die verifizierten

Objekte werden im letzten Schritt zur Multi-Objekt-Segmentierung verwendet. Die einzelnen Schritte werden nachfolgend genauer erklärt. Mögliche Konzepte werden vorgestellt, wobei explizit erwähnt wird, welche Konzepte bereits umgesetzt sind.

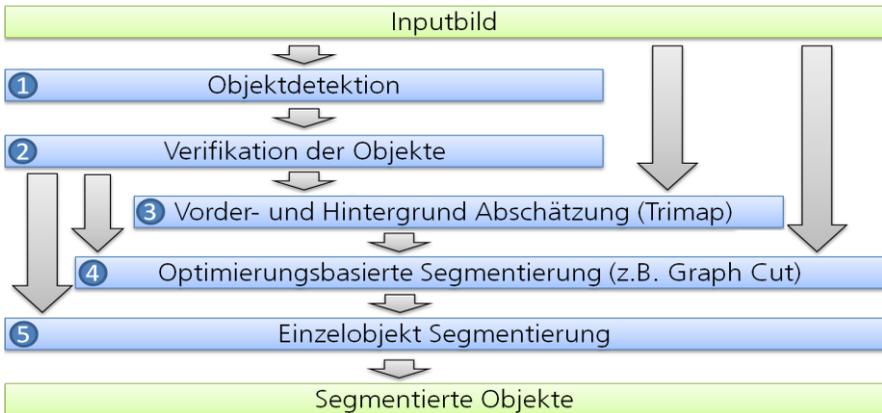


Abb. 3. Generelle Methodik zur Segmentierung von organo-Gruppe.

## 5.1 Objektdetektion

Ziel der Objektdetektion ist die Detektion einiger organischer Objekte. Geeignete Methoden sind Haarkaskaden, HoG und Eigenobjekte. Alle Methoden sind fensterbasiert, rotationsinvariant und klassifizieren einen Bildausschnitt in Objekt oder nicht Objekt. Weiterhin wird jeweils ein Klassifikator benötigt, welcher mit Trainingsbildern angelern wird. Welche Detektionsmethode am besten geeignet ist, ist abhängig vom Objekt und müsste je Objektklasse experimentell untersucht werden. Da in den folgenden Schritten Fehler in der Detektion abgefangen werden sollen, ist ein zeitaufwändiges Anlernen und Validieren des perfekten Klassifikators nicht notwendig. Das Ergebnis der Detektion ist eine Liste rechteckiger Bereiche im Bild, den **Objektfenstern**, womit die Objekte selbst noch nicht segmentiert sind. In der Umsetzung zum Testen des Konzeptes haben wir Haarkaskaden von verschiedenen Objekten antrainiert.

## 5.2 Verifikation der Objekte

Da organische Objekte eines Typs nicht selten sehr verschieden in Form, Farbe und Textur im Bildraum erscheinen, sind die detektierten Objekte zumeist fehlerbehaftet. Die Entfernung von Fehldetektionen ist Ziel dieses Schrittes. Mit Vorwissen, wie Größenbereich, Farbbereich oder Clusterbildung im Bildraum, sollten die besten Resultate erzielbar sein. Dennoch ist auch ohne Vorwissen eine Verifikation möglich. Theoretisch sollten die detektierten Objekte ähnlich sein. Anhand von Farb- und Texturmerkmalen sollten sich Ausreißer finden lassen. Ein mögliches geeignetes Verfahren zur Ausreißerfindung ist RANSAC. In der aktuellen Umsetzung setzen wir allerdings noch Vorwissen ein.

## 5.3 Vorder- und Hintergrund Abschätzung

Das Ziel dieses Schrittes ist die Abschätzung von Vorder- und Hintergrund zur späteren Modellerstellung. Der Vordergrund entspricht der organo-Gruppe und der Hintergrund entspricht dem, was nicht zur organo-Gruppe zählt. Die im vorangegangenen Schritt verifizierten Objektfenster können vollständig und korrekt sein. Ist dies der Fall, so reicht theoretisch eine Segmentierung pro Objektfenster aus. Dennoch kann nicht davon ausgegangen werden. In empirischen Untersuchungen hat sich in den meisten Fällen eine relativ hohe Fehldetektionsrate ergeben. Der Vorder- und Hintergrund kann folglich nur abgeschätzt werden. Die Abschätzung wird im Ergebnis in eine **Trimap**, ein Bild mit drei Zuständen (unbekannt, Vorder- und Hintergrund), gespeichert. Es ergeben sich folgende Möglichkeiten der Trimap-Erzeugung:

1. Kreisstempel: skaliertes Kreis in Objektfenster repräsentiert das Objekt
2. Segmentierung innerhalb des Objektfensters:
  - a. Segmentierung mit der Otsu's Methode
  - b. Aktive Konturen mit Startpunkten am Objektfensterrahmen

In aktuellen Umsetzungen sind 1. und 2.a integriert.

## 5.4 Optimierungsbasierte Segmentierung

Ziel dieses Schrittes ist die binäre Segmentierung des Bildes in Objekt und nicht Objektpixel durch Optimierung/Verbesserung der bisher abgeschätzten Vorder- und Hintergrundpixel in der Trimap. Das Konzept des Schrittes gliedert sich in die drei wesentlichen Teilschritte:

1. Erstellen eines Vorder- und Hintergrundmodells
2. Bestimmung von Wahrscheinlichkeitskarten anhand der Modelle
3. Globale Optimierung & Segmentierung anhand der Wahrscheinlichkeiten

Die Vorder- und Hintergrundmodelle im ersten Teilschritt müssen die Eigenschaften der Objekte und nicht Objekte adäquat beschreiben und eine Ableitung von Wahrscheinlichkeiten ermöglichen. Die Modelle sollten wesentliche Merkmale zusammenfassen. Nutzbare Merkmale sind Textur und/oder Farbe. Formmerkmale sind an dieser Stelle ungeeignet, da die Trimap keine Bestimmung valider Formmerkmale ermöglicht. Eine Möglichkeit sind Gaussian Mixture Models (GMM's) und die Adaption der Mahalanobis Distanz zur Wahrscheinlichkeitsermittlung. Eine andere Möglichkeit ist die Zwischenspeicherung von Vorder- und Hintergrundpixel und die Nutzung einer Dichteabschätzung zur Wahrscheinlichkeitsermittlung. Auf Basis der Vorder- und Hintergrund Wahrscheinlichkeiten ergeben sich mehrere Möglichkeiten der globalen Optimierung zur finalen Segmentierung. Adaptierbare Verfahren sind Markov Random Fields, Believe Propagation und Graph Cut.

In der aktuellen Umsetzung werden Farbmerkmale verwendet und zwei KD-Bäume mit Vorder- und Hintergrundpixel gefüllt. Um einer Über- oder Untergewichtung im Vorfeld entgegenzuwirken, wird die gleiche Anzahl an Pixeln in den KD-Bäumen gespeichert. Dazu wird die gleiche Pixelanzahl im Hinter- und im Vordergrund zufällig ausgewählt. Ein KD-Baum ermöglicht eine effiziente Nachbarschaftssuche. Für jeden Pixel im Ursprungsbild wird die Dichte innerhalb einer Kugelumgebung im RGB-Raum bestimmt. Die Bestimmung erfolgt durch die Suche im KD-Baum und der Ermittlung der Anzahl der in der Kugelumgebung befindlichen Nachbarschaften. Mit dem Bild wird ein gewichteter Graph aufgebaut, wobei ein

Knoten mit genau einem Pixel im Ursprungsbild korrespondiert. Benachbarte Pixel sind im Graph durch Kanten verbunden. Die Gewichte ergeben sich aus den Gradienten. Weiterhin korrespondiert jeder Pixel zum Vordergrund (Source) und Hintergrund (sink). Diese Gewichte ergeben sich aus den Wahrscheinlichkeitskarten. Durch den Graph-Cut-Algorithmus wird der maximale Fluss (min-cut/max-flow) bestimmt und das Bild binär segmentiert. Die verifizierten Objekte werden bei diesem Vorgehen indirekt zur Wahrscheinlichkeitsermittlung genutzt. Wie im Konzept in Abb. 3 dargestellt, ist jedoch ebenfalls eine direkte Nutzung der verifizierten Objekte zur Verbesserungen der Wahrscheinlichkeiten vorgesehen. Dies soll zukünftig anhand einer höheren Gewichtung der Wahrscheinlichkeitskarte vom Vordergrund und/oder einer geringeren Gewichtung des Hintergrundes erfolgen. Hierfür ist die Konzeption einer entsprechenden Funktion der Gewichtung notwendig.

## 5.4 Einzelobjekt Segmentierung

Die Segmentierung in unserer Methodik führt zu einem binären Bild bestehend aus Objekt und nicht Objektpixeln. Die Objekte sind folglich noch nicht getrennt. Ziel dieses Schrittes ist die Trennung/Separierung der Objekte anhand des Binärbildes und der bereits verifizierten Objektfenster. Die denkbaren Möglichkeiten der Trennung sind vielfältig, wie beispielsweise:

- Regionenbasierte Segmentierung auf die Objektpixel im Ursprungsbild
- Trennung an Kanten und/oder starken Gradienten im Ursprungsbild
- Ermittlung von Objektwahrscheinlichkeiten benachbarter Pixel-Gruppen
- Findung von markanten Punkten auf der Objektkontur zur Trennung

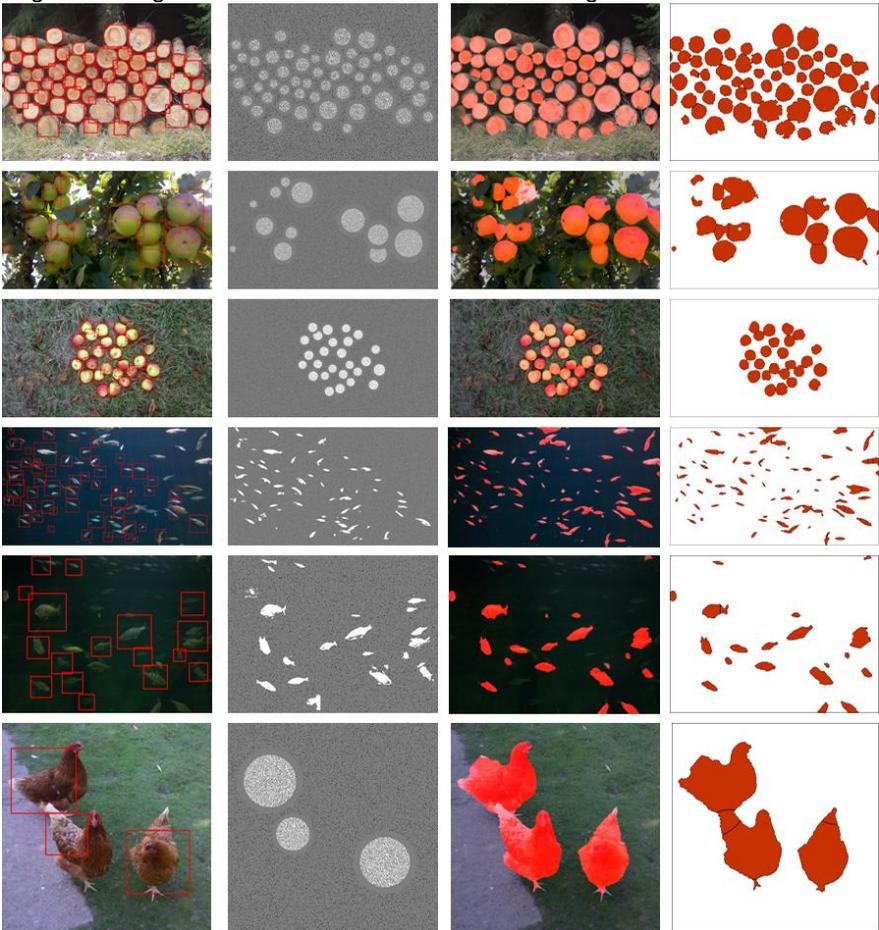
In den aktuellen Umsetzungen wird der LSGMC Algorithmus [22], welcher zur Trennung von Baumstämmen konzipiert wurde, eingesetzt. Die verifizierten Objekte werden erst mit dem Binärbild verschnitten und in eine Maxima-Liste aufgenommen. Ein Maximum enthält die Position und den Radius. Weiterhin werden im, aus dem Schnittbild von Maxima zu Binärbild ermittelten Distanzbild, weitere lokale Maxima gesucht und der Liste hinzugefügt. Alle Maxima wachsen und bewegen sich solange, bis eine gewisse Energie unterschritten ist. Die Energie ergibt sich aus dem Verhältnis von Kreis zu überlagerten Objektpixeln. Überlagern sich mehrere Maxima/Kreise, so werden diese verschmolzen. Sind alle Maxima zum Stillstand gekommen, so werden diese auf das Binärbild abgebildet mit einem gleichzeitigen Region Growing aller Maxima.

## 6 Diskussion der Ergebnisse

Die entwickelte Methodik ist mit Bildern von Äpfeln an einem Baum, Äpfel auf dem Boden, Fischen unter Wasser und Hühnern getestet worden. Erste Ergebnisse sind in Abb. 4 zu sehen. Subjektiv eingeschätzt mit Noten von 1 bis 6 (1 - perfekte Segmentierung) ergeben sich folgende Resultate:

- Segmentierung von Stammschnittflächen: 1 bis 2
- Segmentierung von Äpfeln am Boden: 1
- Segmentierung von Äpfeln am Baum: 2 bis 5
- Segmentierung von Fischen unter Wasser: 1 bis 3
- Segmentierung von Hühnern im freien: 2 bis 6

Die generalisierte Methodik für organo-Gruppen ermöglicht trotz Anpassung immer noch sehr gut die Segmentierung von Stammschnittflächen und sehr gut die Segmentierung von Äpfeln am Boden. Auch Fische unter Wasser lassen sich sehr gut segmentieren. Begründet sind die guten Ergebnisse, da zumeist nur wenige Überschneidungen in der Vorder- und Hintergrundfarbe vorkommen. Bei Hühnern und Äpfeln am Baum ist die Überschneidung größer. Auch kommt es zu sehr vielen Fehldetektionen im ersten Schritt, die nicht alle erfolgreich verworfen werden. Es hat sich auch herausgestellt, dass die Erzeugung der Trimap mit unterschiedlichen Methoden durchgeführt werden muss. Bei kreisähnlichen Objekten ist es ausreichend einen skalierten zentrierten Bereich innerhalb des Objektfensters zu nehmen. Bei anderen Objekten hingegen ist eine Segmentierung innerhalb des Objektfensters notwendig. Speziell hat sich bei Fischen Unterwasser eine Segmentierung mit Otsu's Methode als sinnvoll herausgestellt.



**Abb. 4.** Ergebnisse verschiedener organo-Gruppen von links nach rechts: Inputbild mit verifizierten Objektfenstern; Trimap (weis - Vordergrund, grau - unbekannt, schwarz - Hintergrund); binäre Segmentierung mit Inputbild; separierte Objekte

## 7 Zukünftige Arbeiten

Die Ergebnisse zeigen, dass die vorgestellte Methodik geeignet ist zur Segmentierung von organo-Gruppen. Allerdings ist die aktuelle Umsetzung nur bedingt stabil. Es wurden für die einzelnen Schritten bereits verschiedene Konzepte der Stabilisierung vorgestellt. Die Untersuchung und Evaluierung der Konzepte ist Bestandteil zukünftiger Arbeiten. Die bereits umrissenen Konzepte zusammengefasst mit weiteren möglichen Verbesserungen sind:

- Schritt 1 - Objektdetektion:
  - Fusion verschiedener Detektionsverfahren
- Schritt 2 – Verifikation der Objekte
  - Nutzung von Objektähnlichkeiten zur Verifikation
  - Integration von RANSAC
- Schritt 3 – Vorder- und Hintergrundabschätzung
  - Aktive Konturen zur Segmentierung innerhalb des Objektfensters
- Schritt 4 – Optimierungsbasierte Segmentierung
  - Extraktion von Texturmerkmalen und Verrechnung mit der Wahrscheinlichkeitskarte
  - Verrechnung der verifizierten Objekte direkt mit der Wahrscheinlichkeitskarte
  - Adaption und Evaluierung von Belief Propagation und MRF
- Schritt 5 – Einzelobjekt Segmentierung
  - Regionenbasierte Segmentierung im Ursprungsbild für alle Objektpixel
  - Ermittlung und Trennung an Kanten im Ursprungsbild
  - Ermittlung von Objektwahrscheinlichkeiten benachbarter Pixel-Gruppen und Voting
  - Findung von markanten Punkten auf der Objektkontur kombiniert mit Gradienten im Bild
  - Wachsende und wandernde aktive Konturen

### Literatur:

1. Vishvijit S. Nalwa: *A guided tour of computer vision*. Addison-Wesley, 1993.
2. Nick Efford: *Digital image processing: a practical introduction using Java*. Addison-Wesley, 2000
3. B. Jaehne: *Digital Image Processing*. 6th reviewed and extended edition. Berlin Heidelberg: Springer Verlag, 2005.
4. K.D. Tönnies: *Grundlagen der Bildverarbeitung*. I, Informatik. Pearson Studium, 2005.
5. S.E. Umbaugh: *Computer Imaging: Digital Image Analysis And Processing*. A CRC Press book. Taylor & Francis Group, 2005.
6. Reiner Steinbrecher: *Bildverarbeitung in der Praxis*. 2nd. R. Oldenbourg Verlag, 2004/2006
7. Richard Szeliski. *Computer Vision: Algorithms and Applications*. 1st. New York, NY, USA: Springer-Verlag New York, Inc., 2010.
8. D. Forsyth und J. Ponce: *Computer Vision: A Modern Approach*. Alwayslearning. Pearson Education, Limited, 2011.
9. Mehmet Sezgin und Bülent Sankur. *Survey over image thresholding techniques and quantitative performance evaluation*, Journal of Electronic Imaging, 2004, S. 146-168.
10. Michael Kass, Andrew Witkin und Demetri Terzopoulos: *Snakes: Active contour models*. In: International Journal of Computer Vision 1.4 (1988), S. 321-331.

11. Stanley J. Osher und Ronald P. Fedkiw: *Level Set Methods and Dynamic Implicit Surfaces*. 2003. Aufl. Springer, 31. Okt. 2002.
12. Jos B. T. M. Roerdink und Arnold Meijster: *The Watershed Transform: Definitions, Algorithms and Parallelization Strategies*. 2000.
13. D. Kelkar und S. Gupta: *Improved Quadtree Method for Split Merge Image Segmentation*. In: *Emerging Trends in Engineering and Technology*, 2008.
14. D. Comaniciu und P. Meer: *Mean shift: a robust approach toward featurespace analysis*. In: *Pattern Analysis and Machine Intelligence*, S. 603-619
15. Y. Boykov und V. Kolmogorov: *An Experimental Comparison of Min-Cut/Max-Flow Algorithms for Energy Minimization in Vision*. In: *PAMI*. 2004, S. 1124-1137.
16. J. Shi und J. Malik: *Normalized Cuts and Image Segmentation*. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2000, S. 888-905
17. Paul A. Viola und Michael J. Jones: *Rapid Object Detection using a Boosted Cascade of Simple Features*. In: *CVPR (1)*. 2001, S. 511-518.
18. Roberto Brunelli: *Template Matching Techniques in Computer Vision: Theory and Practice*. Wiley Publishing, 2009.
19. F. Fink: *Foto-optische Erfassung der Dimension von Nadelrundholzabschnitten unter Einsatz digitaler bildverarbeitender Methoden* In: Dissertation, 2004.
20. M.C. Silvia, V.P. Soares, F.A.C. Pinto, C.P.B. Soares und C.A.A.S Ribeiro: *Determination of the volume wooden stacked through processing of digital images*. In: *Scientia Forest Alis* 69 (2005), S. 104-114.
21. E. Gutzeit, S. Ohl, A. Kuijper, J. Voskamp, B. Urban: *Setting Graph Cut Weights for Automatic Foreground Extraction in Wood Log Images*. In: *VISAPP 2010*
22. E. Gutzeit, J. Voskamp: *Automatic Segmentation of Wood Logs by Combining Detection and Segmentation*. *Advances in Visual Computing. ISVC 2012 - 8th International Symposium on Visual Computing. LNCS Vol. 7431, Springer. 2012*
23. C. Fernandez-Maloigne, D. Laugier, C. Boscolo: *Detection of apples with texture analyse for an apple picker robot*, In: *Intelligent Vehicles '93 Symposium*. S. 323-328
24. J. Zhao, J. Tow, J. Katupitiya: *On-tree fruit recognition using texture properties and color data*, In: *Intelligent Robots and Systems, 2005. (IROS 2005)*. S. 263-268.
25. Gao Rui, Liu Gang, Si Yongsheng: *A recognition method of apples based on texture features and EM algorithm*, *World Automation Congress (WAC)*, Sep. 2010, S. 225-229.
26. Cihan Akin, Murvet Kirci, Ece Olcay Gunes, Yuksel Cakir: *Detection of the pomegranate fruits on tree using image processing*. In: *Agro-Geoinformatics (Agro-Geoinformatics), 2012 First International Conference on*. Aug. 2012, S. 1-4
27. Raphael Linker, Oded Cohen, Amos Naor: *Determination of the number of green apples in RGB images recorded in orchards*, In: *Computers and Electronics in Agriculture* 81 (2012), 45(13).
28. C. Aloisio, R.K. Mishra, Chu-Yin Chang und J. English. *Next generation image guided citrus fruit picker*. In: *Technologies for Practical Robot Applications (TePRA), 2012 IEEE International Conference on*. Apr. 2012
29. P. Wijethunga, S. Samarasinghe, D. Kulasiri, I. Woodhead: *Digital image analysis based automated kiwifruit counting technique*. In: *Image and Vision Computing New Zealand, 2008. IVCNZ 2008. 23rd International Conference*. Nov. 2008, S. 1-6
30. J. Betancur, F. Prieto: *Active contour-based segmentation of coffee cherries images*. In: *Signal Processing, 2008. ICSP 2008*, S. 2738-2741
31. Jia-Hong Lee, Mei-Yi Wu, Zhi-Cheng Guo. *A tank fish recognition and tracking system using computer vision techniques*". In: *Computer Science and Information Technology (ICCSIT), 2010 3rd IEEE International Conference on*. Bd. 4. 2010, S. 528-532
32. Gaby Gorsky u. a.: *Digital zooplankton image analysis using the ZooScan integrated system*". In: *Journal of Plankton Research* 32.3 (2010), S. 285-303
33. Lu-Min Zhu, Yong-Liang Zhang, Wen Zhang, Zhu-Cheng Tao, Chao-Fan Liu: *Fish motion tracking based on RGB color space and interframe global nearest neighbour*. In: *Automatic Control and Artificial Intelligence (ACAI 2012)*, 2012
34. N. Otsu: *Threshold selection method from gray-level histograms*. In: *IEEE Transactions on Systems, Man and Cybernetics*. 1979, S. 62-66.