Vollständige Oberflächenprüfung von Orangen mittels Farbbildverarbeitung

Autoren:

- Technische Universität Ilmenau
  - Karl-Heinz Franke
  - Daniel Kapusi
- Zentrum für Bild- und Signalverarbeitung e.V.
  - Rico Nestler
  - Dietmar Kollhoff
  - Carsten Lucht

Dank an:

- Technological Educational Institute of Crete, Branch of Chania
  - ***Prof. G. Kalikatsos, Prof. G.-O. Glentis und Prof. E. Antonidakis***
- Genossenschaft ***MALEME Co-op*** (Kreta)
- Technische Universität Ilmenau
  - Privatdozent ***Dr. P. Zocher***
  - Studenten ***Ch. Karl, S. Rührschneck, Th. Leucht, D. Güllmar***

Oberflächenprüfung von Orangen

Inhalt:

- Problemstellung bei der Kontrolle von Zitrusfrüchten
- Klassifikation befallener Oberflächenareale
  - Freistellung der Orangen
  - Harte Maximum-Likelihood-Klassifikation
  - Partitionierende Clusteralgorithmen → verbesserte Klassenbeschreibungsräume
  - Membershipfunktionen auf der Pixelebene und Bayessche Filterung
- Globale und regional integrale Merkmale
  - Fuzzy-Region-Growing
  - Regionenmerkmale und symbolischer Klassifikator
- rechentechnische Umsetzung, Hardwarestruktur, Echtzeit und Parallelität

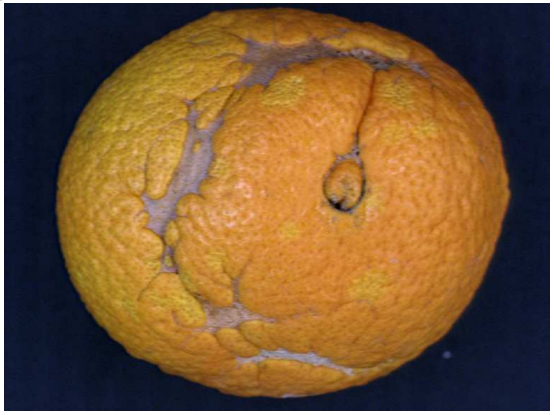

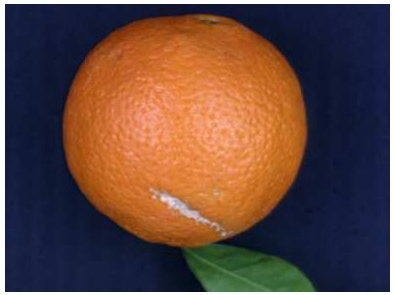

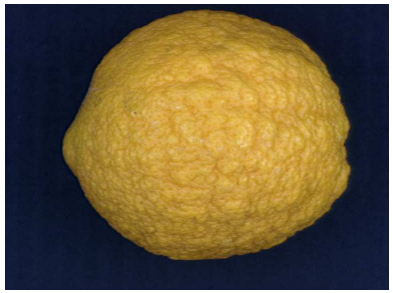

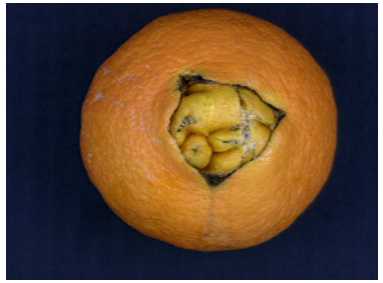

Problemstellung

allgemein:

- visuelle Qualitätsprüfung von Agrarprodukten / Lebensmitteln: → meist ***Farb*** - und Formmerkmale
  - Finden von Schadstellen und Bewerten (lokaler Zusammenhang, „Stärke“)
  - Klassifikation: Abfall ↔ gut
    ↔ diverse Gutklassen
  - Rückkopplung zum Erzeuger (Pflanzenschutzmittel, Lagerhaltung etc.)

konkret → Orangenproduktion auf Kreta:

- Bäuerliche Einzelproduktion und zentrale Sortierung / Verpackung / Vermarktung über MALEME Co-op
- Kontrolle der vollständigen Oberfläche
  - Messung der Stärke des Befalls (Statistik, Rückkopplung zum Erzeuger)
  - Ausschleusen von Abfall
  - Sortieren nach
    - Exportqualität
    - Inlandvermarktung (einzeln)
    - Inlandvermarktung (Netz)
    - Versaftung
    - Degreening nach unterschiedlichen Stufen
- Durchsatz in Erntezeit: mehrere hundert Tonnen pro Schicht

Freistellung der Orangen

- Je nach Auslegung der Sortierstation ***kann der Hintergrund sehr stark variieren***.
- Insbesondere können Farbvalenzen des Hintergrundes und der Schadstellen völlig übereinstimmen.
- Wegen der Aussagen zum Schadensbild (Statistiken) sind die Orangen einschließlich aller Schadstellen vom Hintergrund zu trennen!

- Der ***Bunttonwinkel (Hue)*** liefert ein sicheres Maß für die Freistellung der gesunden Schale, wenn man ***unsichere Bunttöne für kleine Sättigungen (hell) oder kleine Intensitäten (dunkel)*** ausschließt.

- Die ***Schadstellen müssen in die Objektmaske eingefügt*** werden:
  - Segmentierung der Komplementpixel zur gesunden Schale (Hintergrund und Defekte)
  - Extraktion von Formmerkmalen, Klassifikation und füllen der „inneren“ Schadstellen

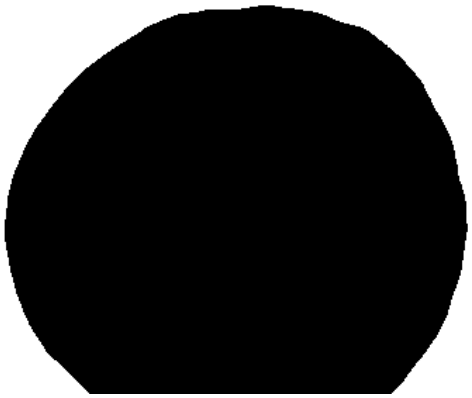

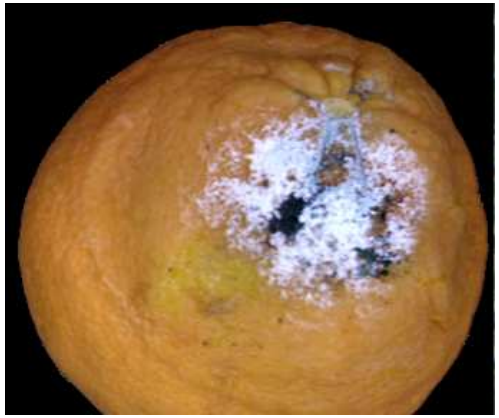

Freistellung der Orangen

- ***Problemfall:*** Schadstellen am Orangenrand verbinden sich mit dem Hintergrund → Hough-Transformation für Kreise zum Schließen des Randes

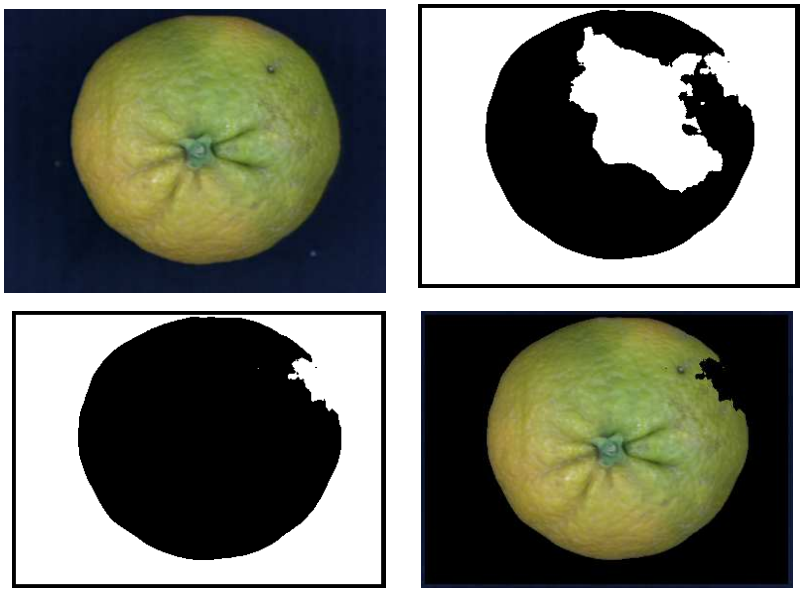

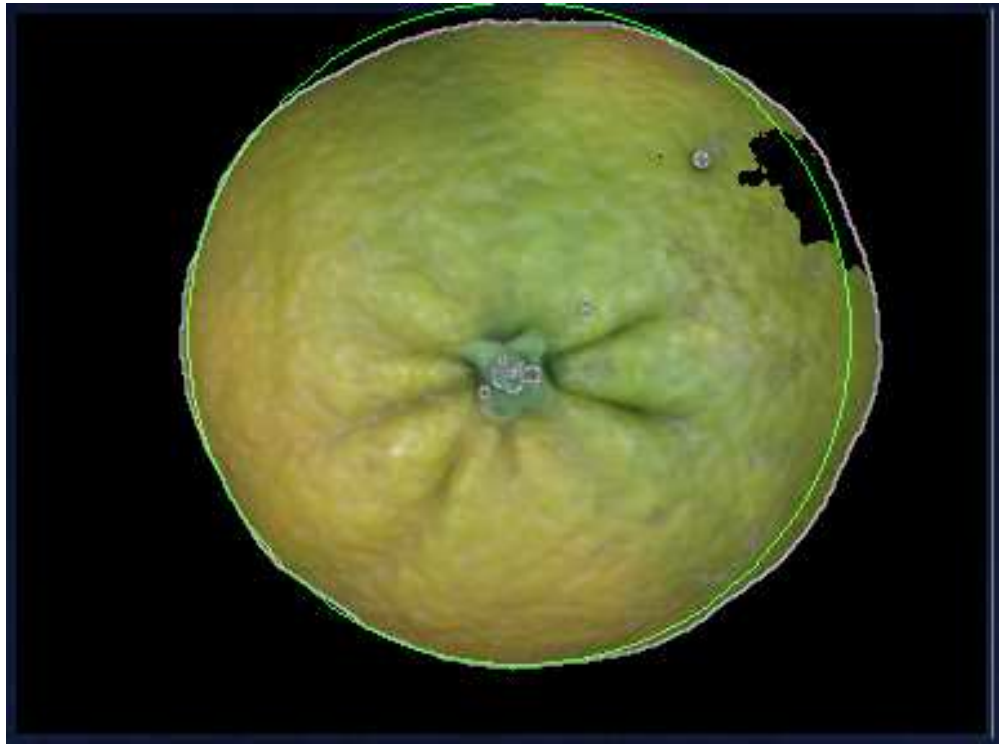

- ***Ganzkörperinspektion im freien Fall*** (sequentielles Blitzen, Simplexanordnung):
  → sichere und vollständige Freistellung durch Hintergrundgestaltung möglich (z.B. helles, gesättigtes Blau / Verwendung von Hue, unterstützt durch Sättigung und Intensität)

Harte Maximum-Likelihood-Klassifikation

- Modellierung der Klassen mit multivariaten Gaußdichten

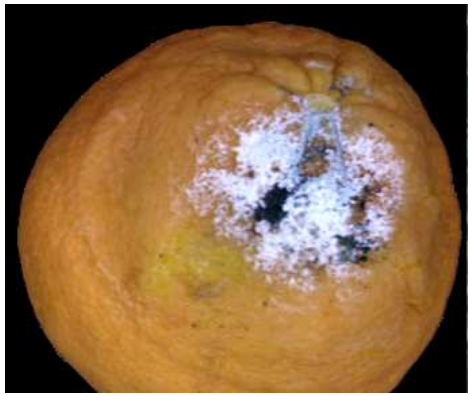

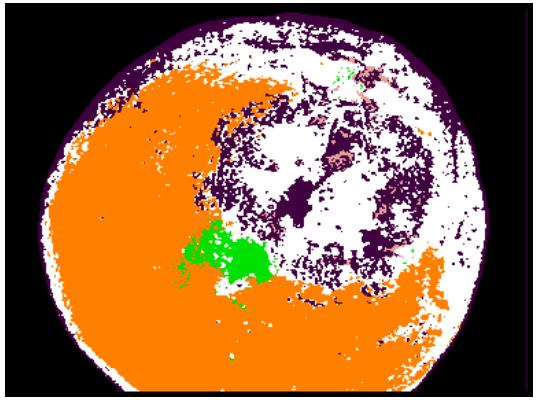

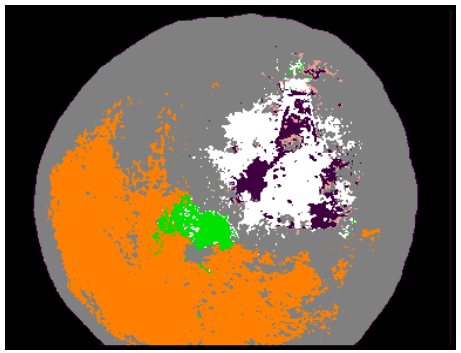

Labelfarben:

- gut
- weißer Schimmel
- schwarzer Schimmel
- grün
- Fäule
- Schorf

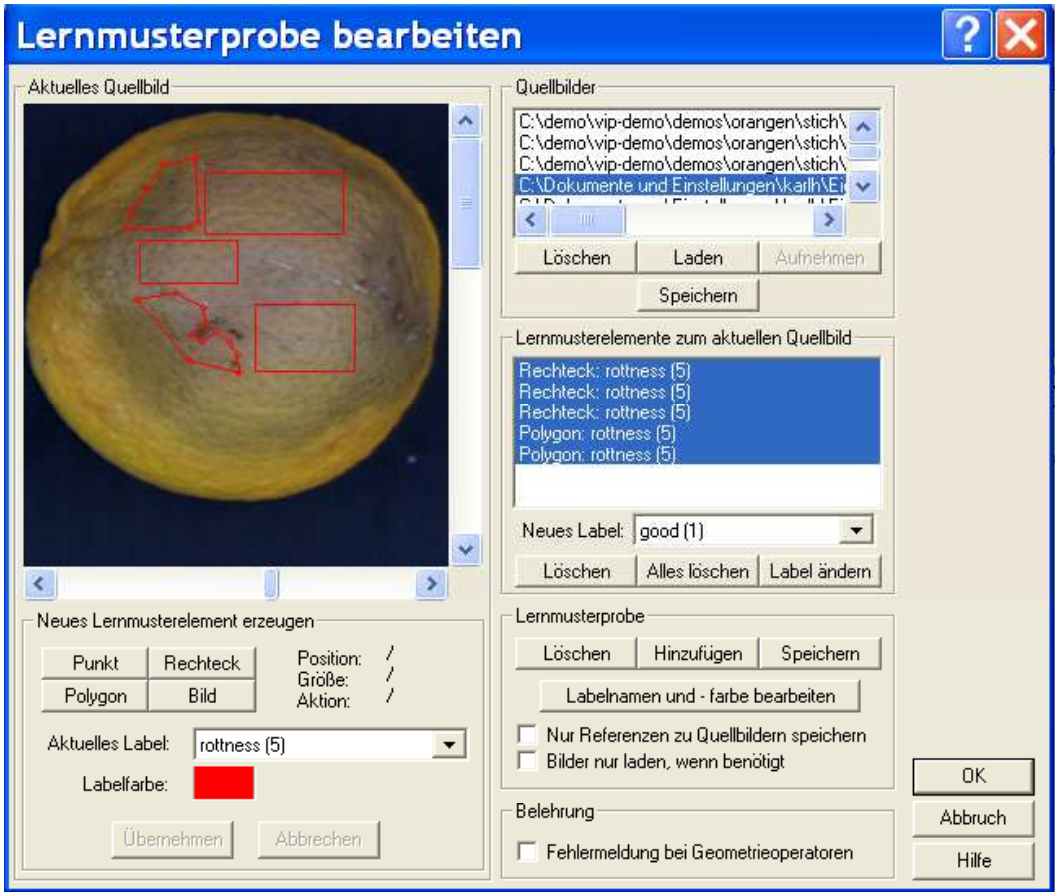

- ***Unzureichende Modellierung der Klassenbeschreibungsräume wird deutlich***
  - → Klassen „gut“ bis „Fäule“ liefern bereits sehr unpräzise Ergebnisse (oben Mitte)
  - → das Aufnehmen von „Schorf“ verschlechtert die Ergebnisse weiter erheblich (rechts unten)

Partitionierende Clusteralgorithmen zur Verbesserung der Klassenbeschreibungsräume

- objektbedingte Variabilität der Naturprodukte erfordert ***komplexe Formen der Klassenbeschreibungsräume*** (rechts: Gutcluster für 10.000 Samples und Modellierung durch eine Partition aus 6 multivariaten Teilclustern)

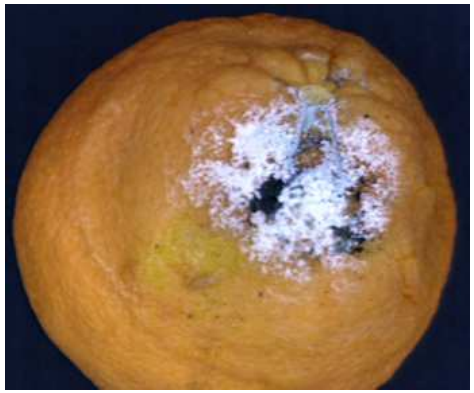

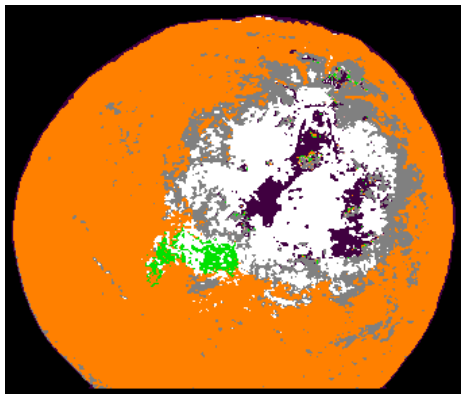

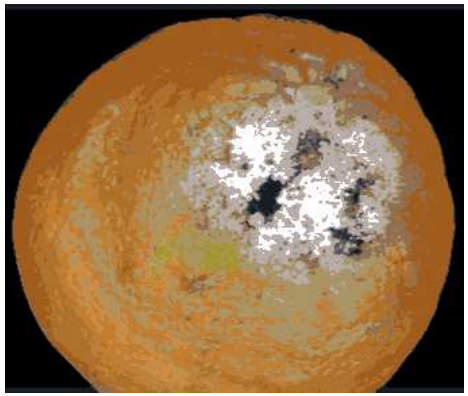

Labelfarben:
- gut
- weißer Schimmel
- schwarzer Schimmel
- grün
- Fäule
- Schorf

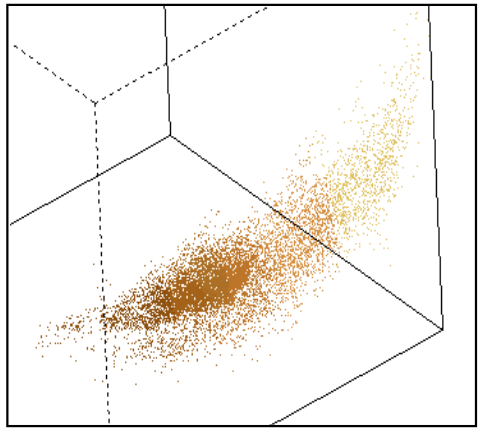

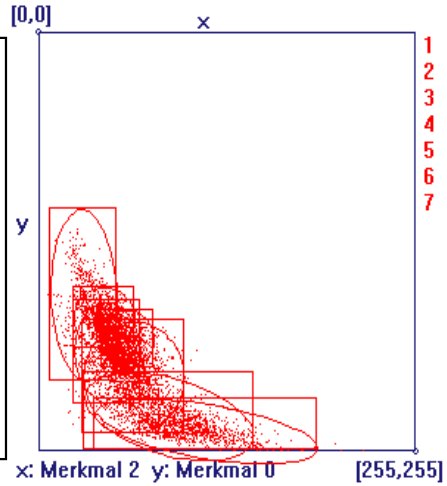

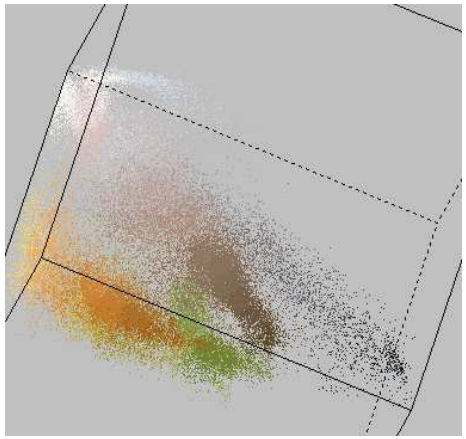

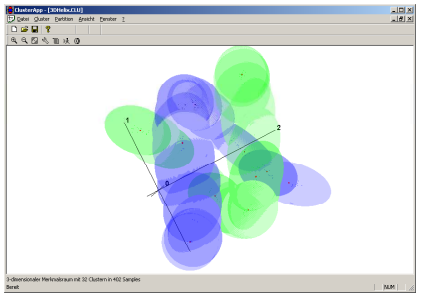

- ***erhebliche Verbesserung wird deutlich***
- ClusterLib wird vom ZBS angeboten
  www.zbs-ilmenau.de/html/prod/cluster.html

Nutzung von Membershipfunktionen auf ikonischer Ebene

- ***Ziel der Erzeugung / Nutzung von Membershipbildern***
  - Vermeidung von Quantisierungsfehlern durch harte Pixelklassifikation →
  - qualifizierte Auswertung von Nachbarschaften (Filterung)
  - membershipbasierte Merkmalextraktion

- Jedem Pixel wird auf ikonischer Ebene ein ***Vektor*** zugewiesen, ***dessen Komponenten die Auftritts-wahrscheinlichkeiten des Inputsamples für die einzelnen Klassen*** beinhalten.
- Erforderlich ist die Kenntnis der bedingten Wahrscheinlichkeitsdichte $w(\underline{X}/C_k)$, die, wie oben erwähnt, oft durch multivariate Gaußdichten modelliert

$$w(\underline{X}/C_k) = \frac{1}{\sqrt{(2\pi)^n} \cdot \sqrt{Det(\underline{\underline{KK}}_k)}} \cdot e^{-\frac{1}{2} \cdot d_{mhl}(\underline{X}/C_k)}$$

oder durch komplexe Partitionen approximiert wird.

- Die Memberships der Pixel ergeben sich im Sinne der ***Bayesschen a posteriori – Wahrscheinlich-keiten*** aus diesen Dichten unter der Annahme ***gleicher Gewichte (Kosten * a priori Wahrscheinlichkeiten)*** und durch Normierung.

$$P(C_k/\underline{X}) \propto w(\underline{X}/C_k) \quad falls \;\; P(C_i) = P(C_j) \forall i \neq j$$

Nutzung von Membershipfunktionen auf ikonischer Ebene

- ***Ergebnis: Membershipbilder*** für die unten angegebenen Klassen

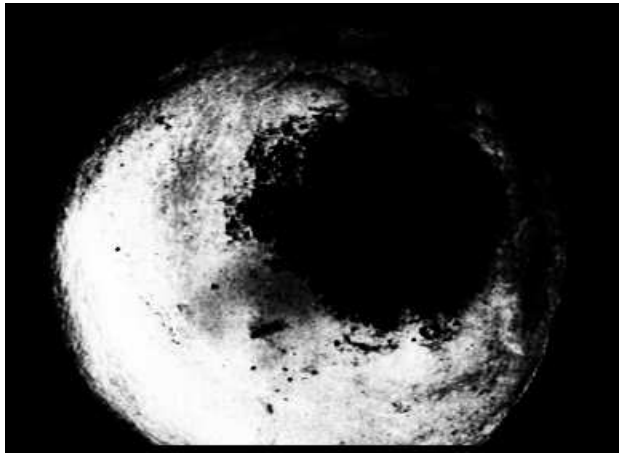

- gut

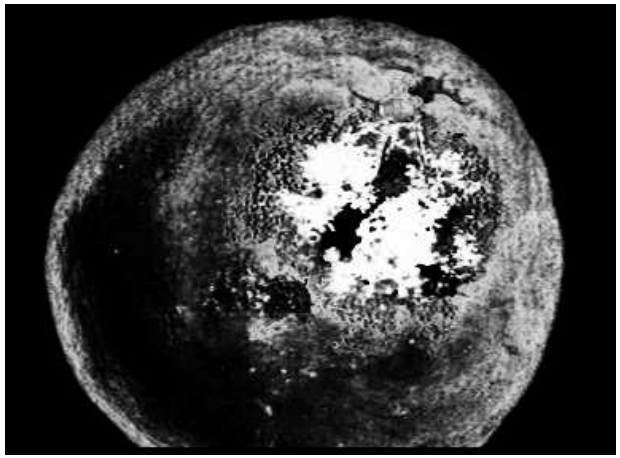

- weißer Schimmel

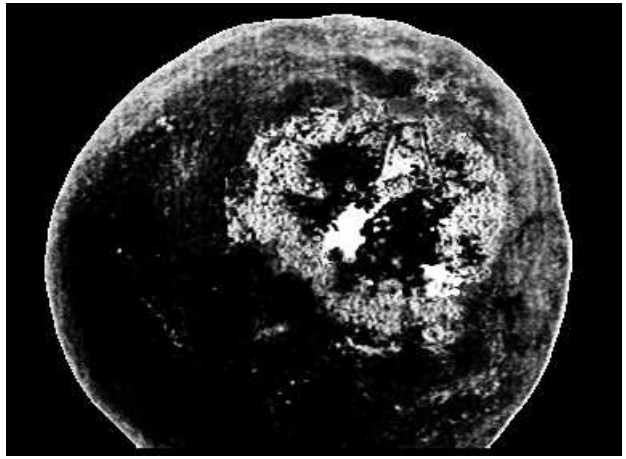

- schwarzer Schimmel

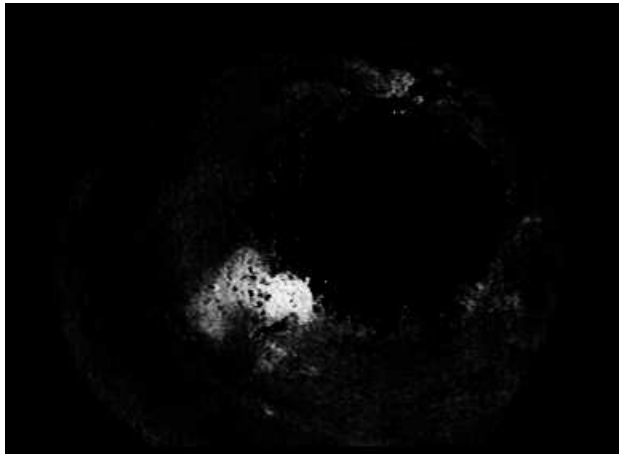

- grün

- Fäule

Bayessche Filterung

- Die Membership der N Pixel der lateralen Nachbarschaft U des Aufpunktes P_0 soll zunächst zur ***Beseitigung von Ausreißern*** und zur ***regionalen Glättung*** genutzt werden

- Die ***Bedeutung der jeweiligen Klasse in der betrachteten Region*** wird durch die mittlere Auftrittswahrscheinlichkeit geschätzt. In Anlehnung an die a priori – Wahrscheinlichkeiten des Gesamtproblems (Prior) soll diese Größe als „lokaler Prior“ bezeichnet werden.

$$P(C_k)\big|_{U(P_0)} = \frac{\frac{1}{N}\sum_{i=1}^{N} P(C_k / \underline{X}_i)}{\sum_k \left(\frac{1}{N}\sum_{i=1}^{N} P(C_k / \underline{X}_i)\right)}$$

- Die ***Stärke des Umgebungseinflusses*** wird über eine Konstante festgelegt, den ***Grad der Schärfe*** $GdS \in \Re[0,1]$. Je höher GdS, desto stärker ist die Klassenentscheidung durch den lokalen Prior, d.h. durch die lokale Nachbarschaft beeinflusst.

$$\arg\max_{C_k} \{P(C_k / X_0)\} \propto \arg\max_{C_k} \left\{ w(\underline{X}_0 / C_k)^{1-GdS} \cdot P(C_k)\big|_{U(P_0)}{}^{GdS} \right\} \quad GdS \in \Re[0,1]$$

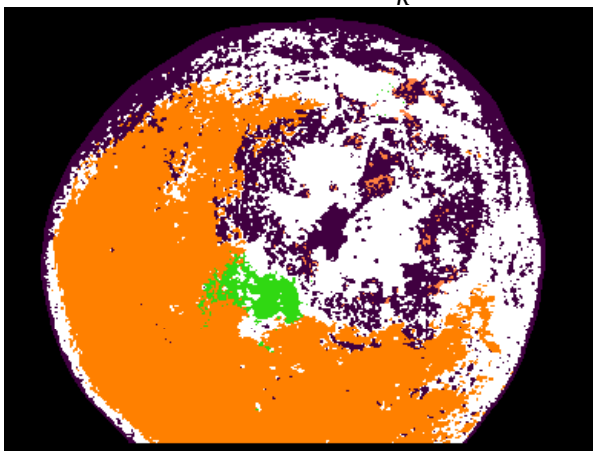

Die Abbildung rechts entsteht für N=7*7-1 und GdS=0.8

Bayessche Filterung der Membershipbilder

- ***alternativer Weg:*** Bayessche Filterung der Membershipbilder (ohne Klassenentscheidung) → Segmentierung auf Basis der Klassenzugehörigkeitsmaße → fuzzy-geometrische Merkmale → symbolische Klassifikation

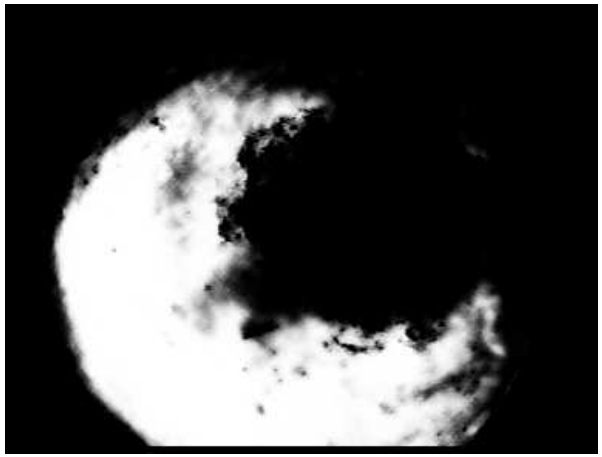

- gut

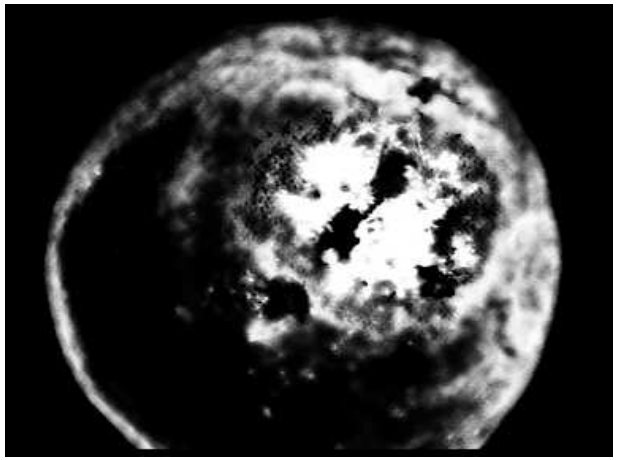

- weißer Schimmel

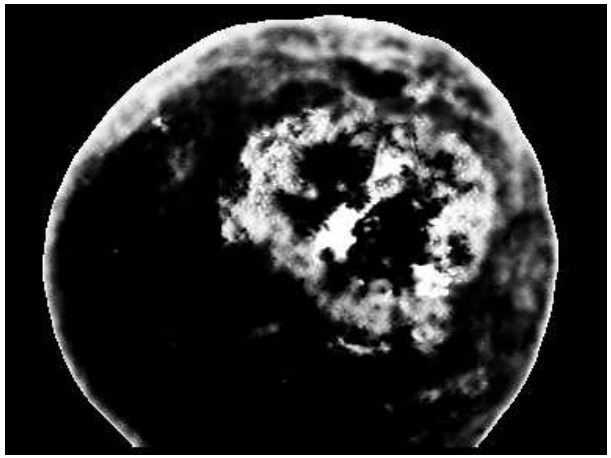

- schwarzer Schimmel

Bayesgefilterte Membership-bilder der fünf Klassen:

Jedes Pixel gehört mit unterschiedlichem Maß zu jeder Klasse, die unscharfen Übergänge und „konkurrierende“ Regionen sind gut zu erkennen

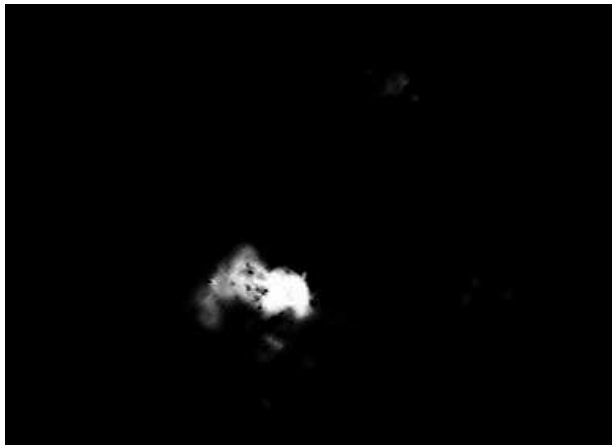

- grün

- Fäule

Segmentierung unter Verwendung von Klassenzugehörigkeiten

- ***Rein globale Merkmale sind in vielen Fällen ungeeignet*** (Zusammenhangsaussage fehlt, regionale Merkmale fehlen / zusammenhängende weiße Schimmelstellen oder viele „weiße“ Einzelreflexe auf gewachster Schale).
- Zur Fortführung des unscharfen Verarbeitungskonzeptes und Vermeidung von Quantisierungseffekten aus einer scharfen Segmentierung
  → ***FUZZY – REGION - GROWING***
  - ***Jeder Saatpunkt wächst einzeln*** bis zum vollständigen Segment (ist möglich, weil Segmente mit entsprechenden Zugehörigkeitswerten ineinander laufen dürfen, beeinflussen sich im Wachstum gegenseitig nicht)
  - ***Saatpunkte: Minima in den Streuungsbildern*** der Einzelkanäle, d.h. sitzen in möglichst homogenen Regionen
  - Für potentiell anzulagernde Pixel AP wird der ***Erfüllungsgrad des Homogenitätskriteriums*** $\mu_{H\,AP}$ ermittelt. Er resultiert aus einer geeigneten Distanz zwischen Pixelmerkmal- und Segmentmerkmalvektor, z.B. über eine ***Z-Zugehörigkeitsfunktion***.

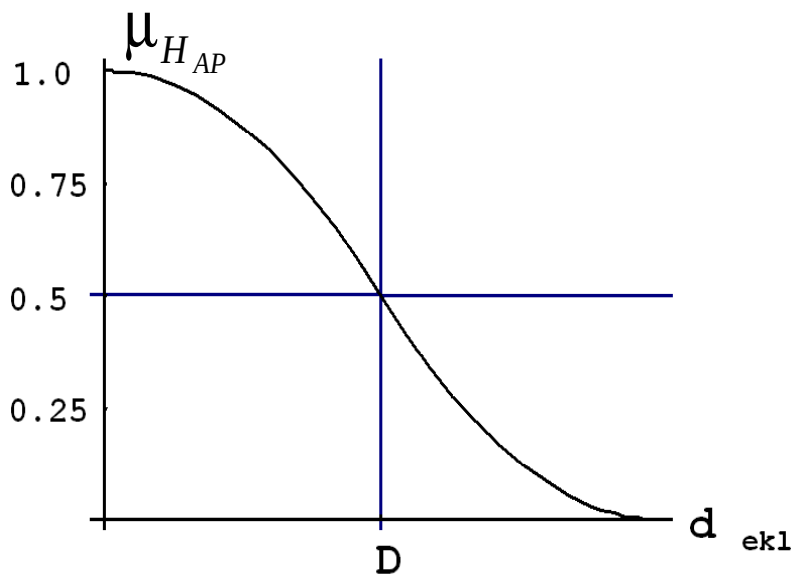

Segmentierung unter Verwendung von Klassenzugehörigkeiten

- Die ***Angliederung eines Pixels*** erfolgt über eine ***Verknüpfung mit seinem „Ursprungsrandpixel“*** UP. Dies ist jenes, das aus der Menge der in Frage kommenden benachbarten Randpixel die größte Segmentzugehörigkeit aufweist.
- Die ***Fuzzy-Verbundenheit*** (fuzzy-connectedness) des Anlagerungspunktes ergibt sich dabei zu:

$$\mu_{S_{AP}} = min\left(\mu_{H_{AP}}, \underset{UP}{arg\,max}\left(\mu_{S_{UP}}\right)\right)$$

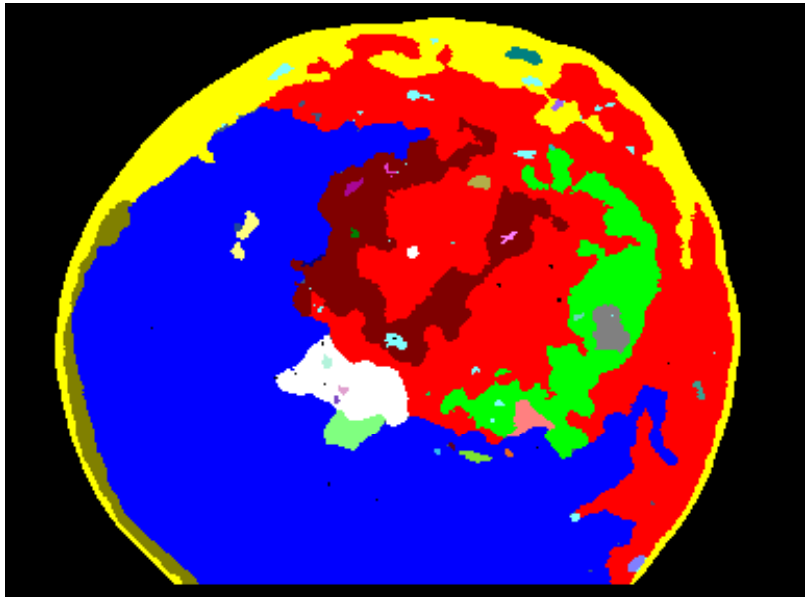

- Der Algorithmus endet nach Zuordnung aller unmaskierten Pixel.
- ***Jedes Pixel ist dann vollständig auf die Segmente aufgeteilt***. Es gehört mit einem bestimmten Grad gleichzeitig zu mehreren Segmenten.
- Zu Darstellungszwecken wurde im Bild links für jedes Pixel das Segment mit dem größten Zugehörigkeitswert dargestellt.

Regionenmerkmale und symbolischer Klassifikator

- Je nach Segmentierungsvariante (scharf / unscharf) werden ***geometrische bzw. fuzzy-geometrische Merkmale*** berechnet.
- Für Schadstellen auf und Reifegrad von Orangen sind das z.B. ***Flächen, Flächenverhältnisse*** oder auch ***Formfaktoren***. Dazu kommen ***Texturmaße***, ***Objektgröße*** und ***Objektform*** sowie Merkmale von anderen Sensoren (Gewicht)

- Bewertung von ***fuzzy-geometrischen Segmenteigenschaften*** erfolgt durch ***unscharfe Klassifikation*** über Fuzzy-Inferenz-Systeme. Die Ergebnisse werden mit den Attributen der zugehörigen Pixel (z.B. mittlere Farbvalenzen bzw. Klassen der ikonischen Klassifikation) zu Regionenmerkmalen verknüpft.
- Es entstehen ***neue Klassen*** (bei Orangen ***z.B. „Schimmel-weiß-kleinflächig", „Schimmel-weiß-großflächig"***), die für die endgültige symbolische Klassifikation geeignet sind.
- Auf diese werden die kleinflächigen und großflächigen Regionen verteilt, die wiederum mit der Zugehörigkeit der betrachteten Segmente z.B. zum ikonischen Merkmal „weißer Schimmel" gewichtet werden.

- ***Endgültige Klassifikation:*** Abfall, mehrere Degreening-Klassen, Versaftung, mehrere Gutklassen für unterschiedliche Marktsegmente (Export, Inland Kistenware, Inland Netzware, . . .)

Hardwarestruktur und Performance

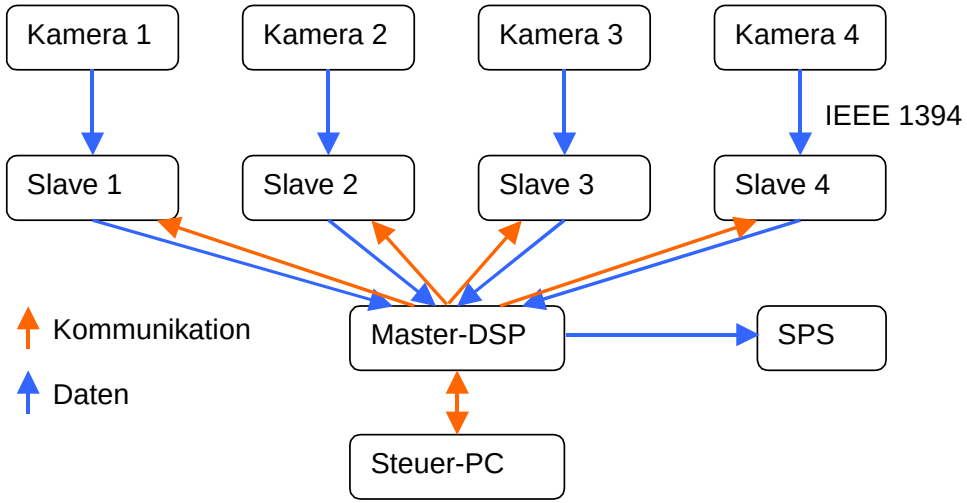

- ***Vollkörperaufnahme*** (***vier Kameras*** mit dicht hintereinander folgenden Blitzaufnahmen im freien Fall) und Datendurchsatz führen auf ein teilweise parallel arbeitendes Mehrfach-DSP-System.
- Die Verarbeitung der vier Einzelansichten erfolgt in ***Slave 1 bis 4***
- Der ***Master-DSP*** übernimmt die Zusammenfassung der Teilergebnisse und die Endklassifikation.

- Außerdem übernimmt der Master-DSP die Ansteuerung der ***SPS*** und die Kommunikation mit dem ***Steuer-PC***. Die Verbindung zum Steuer-PC ist insbesondere für die Konfigurations- und Lernphase sowie das Downloaden von Daten für die DSPs wichtig.

- ***Performance:***
  - Reine PC-Lösung: ca. 330 ms / Frucht. → reicht nicht aus!
  - DSP-Struktur: ***13 ms / Frucht***, d.h. ca. ***60 Objekte pro Sekunde***
  - Orangen-Problem bleibt darunter (logistische Grenzen), Ausschöpfung der Performance ist aber für andere Applikationen (Schüttgüter) erforderlich.