

# Fuzzy-Farbbildanalyse zur Qualitätsbewertung von Produktionsfleisch

Ralf Borau

Gesellschaft zur Förderung angewandter Informatik e.V. (GFal)  
Rudower Chaussee 30, 12489 Berlin-Adlershof  
E-Mail: borau@gfai.de

## 1 Einleitung

An verschiedenen Stellen in der fleischverarbeitenden Technik existiert die Auffassung, dass sich Qualitätsmerkmale von Fleisch aus seiner Farbe ableiten lassen. Diese Auffassung wurde auch durch wissenschaftliche Untersuchungen in der Lebensmitteltechnik bestätigt. Vor diesem Hintergrund entstand das Ziel, bestimmte Qualitätsmerkmale von Produktionsfleisch mit Hilfe einer digitalen Farbbildanalyse automatisch zu erfassen. Die Arbeiten hierzu wurden in den Jahren 2001-2004 in der GFal ausgeführt, wobei das Professor Hellriegel-Institut Bernburg e. V. seitens der Lebensmitteltechnik am Projekt mitwirkte.<sup>1</sup>

Ein Ziel war eine automatische Klassifikation von Produktionsfleisch nach den Vorgaben des GEHA-Standards, der vom Deutschen Fleischerverband für die Qualitätsbewertung von Produktionsfleisch geschaffen wurde. Dabei werden die Fleischsorten je nach Sortierklasse (Kalb, Kuh, Rind, Schwein, Pute) in vier bis zwölf Qualitätsklassen eingeteilt. Die Qualitätsklasse einer Charge (Fleischkiste) wird bisher durch menschliche Inspektionen ermittelt. Aufgrund der subjektiven Gegebenheiten kommt es dabei häufig zu Fehlklassifizierungen. Ein zusätzliches Ziel war die automatische Erkennung der Gewebsbestandteile Muskel-, Fett- und Bindegewebe als ein Beitrag zur Bewertung der Zusammensetzung des Fleisches. Mit dem entwickelten Prototypsystem wurde eine Grundlage für eine lückenlose und reproduzierbare Überwachung der genannten Qualitätsmerkmale von Produktionsfleisch geschaffen.

Das System verwendet einen speziellen Hardwareaufbau zur Bildakquisition. Dieser besteht aus einer CCD-Farbbildkamera (Jenoptik ProgRes C10) und einer speziellen Anordnung mehrerer Leuchtstoffröhren, die unter den Gesichtspunkten hohe Farbtreue und -stabilität, große Helligkeit und geringe Schattenbildung (diffuse Beleuchtung) entworfen wurde. Die Aufgabe der Software ist es, zum einen die vorliegende Qualitätsklasse des Fleisches zu erkennen und zum anderen die im Bild sichtbaren Gewebsarten (Muskel-, Fett- und Bindegewebe) zu unterscheiden. Themenschwerpunkte bei der Software-Umsetzung waren Farbe im allgemeinen,

---

<sup>1</sup> Das Projekt mit dem Titel "Innovative Technologien zur Prozesssteuerung und -bewertung in der Fleischwirtschaft auf der Basis digitaler Fuzzy-Farbanalyse" wurde im Rahmen des InnoNet-Förderprogramms durchgeführt (Reg.-Nr. 16IN0061).

eine reproduzierbare Farbmessung mittels einer CCD-Farbkamera sowie die Farbbildverarbeitung und Farbbildanalyse mit Fuzzy-Methoden.

## 2 Farbmétrische Kalibrierung

Da sowohl Kameraparameter als auch Beleuchtung in der Regel zumindest langfristig größere Veränderungen aufweisen, lassen sich zu unterschiedlichen Zeitpunkten aufgenommene RGB-Farbwerte nur schwer direkt miteinander vergleichen. Aus diesem Grunde wurde eine Kalibrierung des Aufnahmesystems geschaffen, die eine Vergleichbarkeit der Farben im CIE Lab-Farbsystem ermöglicht.

Ziel der Kalibrierung ist es, eine Abbildung des von Beleuchtung und Kamera abhängigen RGB- in den Lab-Farbraum zu finden. Ein linearer Primärfarbenansatz ist bei einer 3-Chip-Kamera, wie sie bei diesem System verwendet wird, für gegebenen Anforderungen zu ungenau. Aus diesem Grund wurde ein polynomieller Regressionsansatz entwickelt – eine vergleichbare Lösung für Farbscanner kann auch bei [Steckert 2004] gefunden werden. Mit Hilfe der Regressionsanalyse kann eine Abbildung  $F_N$  direkt in den CIE Lab Farbraum bestimmt werden. Als Basis wurden allgemeine Polynome vom Grade  $N$  ausgewählt.

$$\begin{pmatrix} L_N(R, G, B) \\ a_N(R, G, B) \\ b_N(R, G, B) \end{pmatrix} = A \cdot P_N(R, G, B) = F_N(R, G, B)$$

Zur Bestimmung der Koeffizientenmatrix  $A$  ist eine größere Menge von Kalibrierfarben notwendig. Diese Stützstellen werden mit Hilfe einer reflektierenden IT8.7-Farbtafel (siehe Abb. 1) (als Durchlichtvariante im Scannerbereich sehr verbreitet) gewonnen. Eine solche Farbtafel enthält 288 Farbfelder, die einen breiten Bereich des farblichen Spektrums abdecken und die durch ein Laborfarbmessgerät einzeln vermessen wurden, so dass der CIE Lab-Farbwert eines jeden Feldes bekannt ist. Durch die Aufnahme unter den vorherrschenden Betriebsbedingungen wird zusätzlich ein gemittelter RGB-Farbwert für jedes Feld bestimmt. Ausgehend von einer Farbtafel mit  $K$  Farbfeldern (bei IT8.7,  $K=288$ ) und deren Lab-Werten erhält man mit einer Kameraaufnahme die korrespondierenden RGB-Werte.

$$\{(L, a, b); (R, G, B)\}_k \quad 1 \leq k \leq K$$

Um die Güte der Regression zu bewerten, wurden verschiedene Kenngrößen der Abweichungen zwischen den Lab-Stützstellen und den durch das Polynom berechneten Lab-Farbwerten ermittelt. Folgende  $dE$ -Abweichungen werden jeweils für eine durchgeführte Farbkalibrierung mit Polynomgrad  $N=3$  bestimmt:

- $dE_{\max}$ : maximale Abweichung eines Farbfeldes
- $dE_{\text{mean}}$ : mittlere Abweichung aller Farbfelder
- $dE_2$ : mittlere quadratische Abweichung

In der nachfolgende Tabelle sind diese Abweichungen für einige Farbkalibrierungen, die im Laufe des Projektes zu unterschiedlichen Zeitpunkten durchgeführt wurden, gelistet:

<b>Name/Datum</b>	<b><math>dE_{\max}</math></b>	<b><math>dE_{\text{mean}}</math></b>	<b><math>dE_2</math></b>
23.04.2004	6.91	1.69	2.03
01.12.2003	6.89	1.70	2.04
08.12.2003	5.66	1.52	1.83
17.12.2003	6.99	1.80	2.18
16.02.2004	6.52	1.80	2.15

Zwar erscheint der maximale Fehler relativ hoch, jedoch treten diese in der Regel in Bereichen des Farbraums auf, die für dieses Projekt nicht relevant sind. Wenn man davon ausgeht, dass eine farbliche Abweichung von  $dE=1$  in etwa die Genauigkeit der menschlichen Wahrnehmung angibt, so kann ein mittlerer Fehler von ca. 2 als praxistauglich angesehen werden.

Durch diese Farbkalibrierung ist man nun in der Lage, Einzelfarben bzw. Farbverteilungen unabhängig von den zum Aufnahmezeitpunkt vorherrschenden Beleuchtungsbedingungen vergleichen zu können. Für die nachfolgend beschriebene Bildklassifikation ist sie unverzichtbar.

### 3 Bildklassifikation

Aufgabe der Bildklassifikation ist es, jedem Bild (vom Inhalt einer Fleischkiste) eine Qualitätsklasse nach dem eingangs erwähnten GEHA-Standard zuzuordnen. Abb. 3 und Abb. 4 zeigen zwei typische Beispiele solcher Bilder. Grundlage dieser Klassifikation ist der Vergleich mit den charakteristischen Farbverteilungen der einzelnen Qualitätsklassen. Eine solche Verteilung wird durch die Akkumulation einer großen Lernmenge, also vieler Bilder einer Klasse, ermittelt und als 3-dimensionales Fuzzy-Farbhistogramm (siehe Abb. 2) des Lab-Farbraums gespeichert (ein solches Histogramm besteht bei diesem Anwendungsfall aus  $18 \cdot 13 \cdot 13 = 3042$  Einträgen).

Der Abstand bzw. die Ähnlichkeit eines Bildes zu einer bestimmten Qualitätsklasse wird über einen Vergleich des Bildhistogramms mit dem akkumulierten Histogramm ermittelt. Histogrammvergleiche werden häufig im Bereich ‚Image Retrieval‘ benutzt, da sie zu einem gewissen Grad Bildähnlichkeiten ausdrücken können (siehe dazu [Rui u.a. 1999] oder [Swain und Ballard 1990]). Für den Histogrammvergleich kommen verschiedene Abstandsmaße in Frage. Eine große Gruppe von Abstandsmaßen sind die sog. ‚Bin-By-Bin‘-Vergleiche. Diese berücksichtigen nur den Unterschied zweier sich entsprechender Histogrammeinträge  $h_i$  und  $k_i$ . Folgende wurden in diesem Projekt implementiert und getestet (nach [Rubner u.a. 1998]):

- Symetr. Divergenz (Jeffrey):

$$d_J(H, K) = \sum_i \left( h_i \log \frac{h_i}{m_i} + k_i \log \frac{k_i}{m_i} \right) \quad \text{mit} \quad m_i = \frac{h_i + k_i}{2}$$

- Histogrammschnitt:  $d_{\cap}(H, K) = 1 - \sum_i \frac{\min(h_i, k_i)}{h_i}$
- Geometrischer Abstand:  $d_{L_2}(H, K) = \sqrt{\sum_i (h_i - k_i)^2}$
- $X^2$ -Abstand:  $d_{X^2}(H, K) = \sum_i \frac{(h_i - m_i)^2}{m_i}$  mit  $m_i = \frac{h_i + k_i}{2}$

Alle ‚Bin-By-Bin‘-Vergleiche haben den Nachteil, dass nur Unterschiede zwischen Elementen gleicher Indizes berücksichtigt werden. Dieses führt zu einer Empfindlichkeit gegenüber Skalierungen, Rotationen oder Verschiebungen eines Histogramms, die in der Regel nicht erwünscht ist. Durch die in Absatz 2 beschriebenen Ungenauigkeiten der Farbkalibrierung könnten solche Abweichungen des Histogramms durchaus eintreten. Sogenannte ‚Cross-Bin‘-Vergleiche sollten an dieser Stelle bessere Ergebnisse erzielen, z.B.:

- ‚Quadratic-Form‘-Abstand:  $d_A(H, K) = \sqrt{(h - k)^T A (h - k)}$

Die Einträge  $a_{ij}$  der Matrix  $A$  stellen dabei Ähnlichkeiten zwischen den Einträgen  $i$  und  $j$  dar. Die Vektoren  $h$  und  $k$  enthalten alle Elemente von  $H$  bzw.  $K$  entsprechend einer feststehenden (von der Position im Farbraum abhängigen) Sortierung. Bei der Implementierung wurde  $a_{ij} = 1 - d_{ij} / d_{\max}$  gewählt, wobei für  $d_{ij}$  der geometrische Abstand zweier Histogrammeinträge im Farbraum verwendet wird.

Unter Laborbedingungen konnte für diesen Anwendungsfall kein signifikanter Unterschied zwischen den Abstandsmaßen festgestellt werden. In Abb. 5 ist eine beispielhafte Gegenüberstellung der verschiedenen implementierten Abstandsmaße zu sehen. Für jedes Abstandsmaß wurden die Abstände eines Referenzhistogramms zu den Einzelbildern einer Vergleichsbildserie ermittelt. Als Referenz wurde das Histogramm eines Bildes der Sortimentklasse S II verwendet. Die Vergleichsbildserie wurde aus jeweils vier Bildern verschiedener Sortimentklassen, und zwar S II, S IV, KA II und R III, zusammengestellt. Der Abstand der ‚S II‘-Vergleichsbilder zur ‚S II‘-Referenz ist erwartungsgemäß sehr gering. Auch die anderen Werte decken sich mit dem optischen Vergleich. Man kann erkennen, dass sich die Kurvenverläufe aller Abstandsmaße bis auf eine Skalierung nur unwesentlich voneinander unterscheiden. Es ist aber zu vermuten, dass der ‚Cross-Bin‘-Vergleich in der Praxis robuster, also weniger störanfällig sein sollte. Eine Bestätigung dieser Vermutung steht noch aus.

Um die Zuverlässigkeit der Klassifikation zu erhöhen, wird neben dem Histogrammvergleich zusätzlich die Verteilung der sichtbaren Gewebsanteile im Bild berücksichtigt, da diese Anteile auch für die menschliche Einschätzung der Qualitätsklasse ausschlaggebend sind. Ein Lösungsansatz zur automatischen Bestimmung dieser Verteilung wird im folgenden Absatz erläutert.

#### 4 Bildsegmentklassifikation (EM-Algorithmus)

Neben der Erkennung der Qualitätsklasse ist eine weitere Anforderung an das System, die im Bild sichtbaren Gewebsarten (Muskel, Fett und Bindegewebe) zu

unterscheiden und die flächigen Anteile zu bestimmen. Zwei Strategien wurden dafür in Erwägung gezogen.

Bei der ersten müssen die Farbverteilungen jeder Gewebsart im CIELab-Farbraum manuell angelernt werden und die Zuordnung erfolgt über einen Vergleich mit dem statischen, angelernten Wissen. Dieses Vorgehen hat grundlegende Nachteile. Zum einen setzt dieses eine sehr hohe Genauigkeit bei der Bestimmung der Lab-Farben und zum anderen ist dieses Vorgehen mit einem erheblichen Lernaufwand verbunden, da die Farbverteilungen der Sortimentklassen stark variieren können.

Die zweite Strategie, die in diesem Projekt vorrangig verfolgt wurde, sieht eine automatische Unterscheidung, also eine Adaption an die im Bild vorliegenden Verhältnisse, vor. Es wurde ein adaptiver Klassifikationsansatz auf Basis des EM-Algorithmus entwickelt (siehe auch [Richardt u.a. 2002]). Der EM-Algorithmus ist ein iteratives Verfahren, mit dem Anhäufungen, die mehrdimensionalen statistischen Verteilungen entsprechen, erkannt werden können. Das verwendete Modell für eine Verteilung im Farb- bzw. Merkmalsraum, das aufgrund vorhergehender umfangreicher Laborfarbmessungen ausgewählt wurde, ist ein mehrdimensionaler Ellipsoid  $\Omega$ . Er ist durch Mittelwert  $m$ , Kovarianzmatrix  $\Sigma$  und Faktor  $q$  (relative Masse) einer Verteilung bestimmt. Die Distanz eines Vektors  $v$  zum Ellipsoiden wird durch den als (quadratischer) Mahalanobisabstand bezeichneten Abstands begriff (siehe [Duda u.a. 2002], S. 27) ermittelt.

$$d(\Omega, v) = (m - v)^T \Sigma^{-1} (m - v)$$

Dass dieser Abstands begriff  $d$  in die Bestimmung von Zugehörigkeiten eines Vektors zu Ellipsoiden einfließt, entspricht einer intuitiven Vorstellung. Dieser Berechnungsschritt wird als E-Schritt bezeichnet und die Bestimmung von Ellipsoiden auf Basis der Vektoren und deren Zugehörigkeiten als M-Schritt. Beide werden wie folgt ausgeführt:

- Expectation: Zugehörigkeit  $z_{i,k}$  eines Vektors  $v_i$  zum Ellipsoiden  $\Omega_k$

$$z_{i,k} = P_{i,k} / \sum_K P_{i,K} \quad \text{mit} \quad P_{i,k} = q_k \cdot \frac{1}{\sqrt{2\pi|\Sigma_k|}} e^{d(\Omega_k, v_i)}$$

- Maximization: Neuberechnung des Ellipsoiden  $\Omega_k$

$$m_k = \sum_i z_{i,k} v_i \quad \Sigma_k = \sum_i z_{i,k} (v_i - m_k) \cdot (v_i - m_k)^T \quad q_k = \sum_i z_{i,k} / n$$

Die Anzahl aller Vektoren wurde hier mit  $n$  bezeichnet. Beide Schritte werden iterativ im Wechsel ausgeführt, bis ein Gleichgewichtszustand erreicht ist.

Die Güte bzw. Zuverlässigkeit dieses Verfahren hängt in dem konkreten Anwendungsfall entscheidend von der Wahl des Merkmalsvektors ab, da die sich ergebenden Verteilungen als kaum trennbare Klassen vorliegen. Die Gefahr, dass der Konvergenzzustand nicht den gewünschten Klassen entspricht, kann unter Umständen sehr hoch sein. Dieses Risiko kann durch Wahl eines geeigneten Merkmalsvektors reduziert werden. Für die hier vorgestellte Anwendung wird deswegen ein 3-dimensionaler Vektor aus mehreren Elementarmerkmalen zusammengestellt. Diese Merkmale beziehen sich auf zusammenhängende

Bildgebiete, die über ein ‚Split & Merge‘-Verfahren vorberechnet werden. Aus dem gemittelten  $(r,g,b)$ -Farbwert können folgende abgeleitet werden:

- Intensität:  $i = (r + g + b) / 3$
- HSV-Value:  $v_{hsv} = \max(r, g, b) / 255$
- HSV-Saturation:  $s_{hsv} = v_{hsv} - \min(r, g, b) / 255 / v_{hsv}$
- Buntheit (Chroma):  $chroma = |(r - i) / i| + |(g - i) / i| + |(b - i) / i|$

Des Weiteren können einfache Textureigenschaften durch Kenngrößen der Co-Occurrence-Matrix ausgedrückt werden. Für  $N_g$  Graustufen enthält diese Matrix  $N_g$  Zeilen und Spalten. Der Grauwert eines Pixels an Position  $(x,y)$  sei mit  $g(x,y)$  gegeben. Für festen Offsetvektor  $(v_x, v_y)$  berechnet sich jeder Matrixeintrag  $P(i,j)$  wie folgt:

$$P(i, j) = \sum_{x,y} f(x, y, i, j) \text{ mit } f(x, y, i, j) = \begin{cases} 1 & \text{falls } g(x,y) = i \wedge g(x + v_x, y + v_y) = j \\ 0 & \text{sonst} \end{cases}$$

Folgende Kenngrößen (nach [Theodoridis und Koutroumbas 2003], Seite 274f) der Co-Occurrence-Matrix können verwendet werden:

- Angular Second Moment (ASM):

$$asm = \frac{1}{n} \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (P(i, j))^2 \text{ mit } n = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j)$$

- Inverse Difference Moment (IDF):  $idf = \frac{1}{n} \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{P(i, j)}{1 + (i - j)^2}$

- Entropie:  $H_{xy} = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) \log_2 P(i, j)$

Für die automatische Unterscheidung von Muskel- und Fettgewebe im Bild haben sich Kombinationen aus Intensität, Sättigung und ASM bewährt. Abb. 7 zeigt eine Darstellung der Merkmale als RGB-Farbwert im Bild, Abb. 8 ist die Entsprechung im Merkmalsraum inklusive der angelegten Ellipsoiden. Die genannten Merkmalsvektoren zeigen sich bei der Adaption robust und die Klassifikationsergebnisse halten dem optischen Vergleich (siehe dazu Abb. 6 und Abb. 9) stand.

## Literatur

**Duda u.a. 2002** Duda, Richardt O. ; Hardt, Peter E. ; Storck, David G.: *Pattern Classification*. Wiley & Sons, 2002 – ISBN 0-471-05669-3

**Richardt u.a. 2002** Richardt, J. ; Streckenbach, T.; Gruner, C.: *Modular formalism of Deterministic Annealing, EM Algorithm, Clustering and Regression*. In: [www.gfai.de](http://www.gfai.de) . URL: <http://www.gfai.de/forschungsbereiche/fuzzy/pubs/publist.html> (27.09.2002)

**Rubner u.a. 1998** Rubner, Yossi ; Tomasi, Carlo ; Guibas, Leonidas J.: *The Earth Mover's Distance as a Metric for Image Retrieval*. 1998. Stanford University, Department of Computer Science

**Rui u.a. 1999** Rui, Yong ; Huang, Thomas S. ; Chang, Shih-Fu: Image Retrieval: Current Techniques, Promising Directions, and Open Issues. In: *Journal of Visual Communication and Image Representation* 10 (1999), März, Nr 1, S. 39–62.

**Steckert 2004** Steckert, Carsten: Ortsaufgelöste Farbmessung auf beanspruchten Beschichtungen. In: *Inspect Special Edition 1/2004*, GIT Verlag, 2004, S. 4-7

**Swain und Ballard 1990** Swain, M.J. ; Ballard, D.H.: Indexing via color histograms. In: *Proceedings, Third International Conference on Computer Vision*, 1990, Osaka, Japan

**Theodoridis und Koutroumbas 2003** Theodoridis, Sergios ; Koutroumbas, Konstantinos: *Pattern Recognition*. Elsevier Academic Press, 2003 – ISBN 0-12-685875-6



Abb. 1: Aufnahme des reflektierenden Farbtargets zur Farbkalibrierung




Abb. 2: Fuzzy-Farbhistogramm eines Fleischbildes im Lab-Farbraum



Abb. 3: Aufnahme eines Sortiments der Qualitätsklasse S II



Abb. 4: Aufnahme eines Sortiments der Qualitätsklasse R III

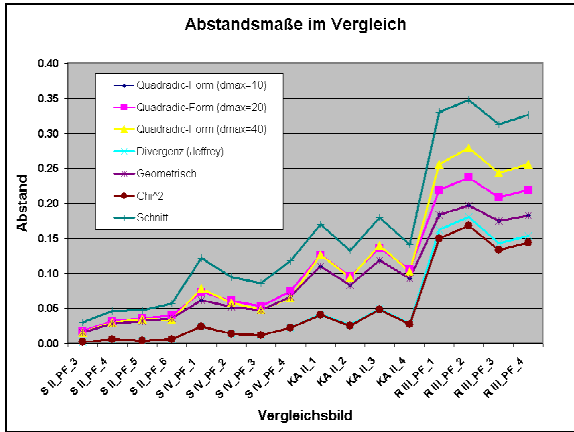


Abb. 5: Vergleich verschiedener Abstandsmaße



Abb. 6: Kiste der Qualitätsklasse S II




Abb. 7: Darstellung der Merkmale




Abb. 8: Angelernte Ellipsoiden (Fett = blau, Muskel = rot) im Merkmalsraum




Abb. 9: Zuordnung der Gewebeklassen (Fett = blau, Muskel = rot)