

Spektrale Bandselektion beim Entwurf automatischer Sortieranlagen

Matthias Michelsburg¹, Robin Gruna², Kai-Uwe Vieth²
und Fernando Puente León¹

¹ Karlsruher Institut für Technologie, Institut für Industrielle
Informationstechnik, Hertzstr. 16, D-76187 Karlsruhe

² Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung
IOSB, Fraunhoferstr. 1, D-76131 Karlsruhe

Zusammenfassung Die automatische Sortierung von Schüttgütern mithilfe verschiedener Methoden der Bildverarbeitung wird in vielen Bereichen – beispielsweise in der Nahrungsmittelindustrie – eingesetzt, um die gewünschte Qualität eines Produkts zu gewährleisten. Für besonders anspruchsvolle Sortieraufgaben reicht das Signal einer einzelnen Graustufen- oder RGB-Kamera nicht aus, um ein zufriedenstellendes Sortierergebnis zu erreichen. Durch Hinzunahme von Spektralbereichen außerhalb des sichtbaren Wellenlängenbereichs kann eine Klassifikation verbessert werden. Eine wichtige Rolle spielt hierbei der Nahinfrarotbereich, welcher in der Spektroskopie seit vielen Jahren zur Qualitätskontrolle und Analytik genutzt wird. Hyperspektrale Bildaufnahmen liefern zu jedem Bildpunkt ein hoch aufgelöstes Spektrum, finden jedoch in Sortieranlagen aufgrund der hohen Kosten, der aufwändigen Signalverarbeitung und der begrenzten Geschwindigkeit weniger Anwendung. Durch Reduktion der Messung auf diejenigen spektralen Bereiche, mit welchen eine gute Klassifikation möglich ist, kann ein einfacheres und schnelleres Sortiersystem entworfen werden. An einem Beispiel wird ein Ansatz zur Selektion dieser Bänder aus hyperspektralen Bildern vorgestellt und bewertet.

1 Einleitung

Die automatische Sortierung von Schüttgütern findet in verschiedenen Bereichen Anwendung. Ein wichtiger Bereich ist die Sortierung von

Kunststoffen. Durch die Verknappung von Ressourcen muss mit Rohstoffen sehr effizient umgegangen werden und Ausgangsstoffe durch Recyclingprozesse rückgewonnen werden, was nicht zuletzt durch aktuelle Umweltauflagen und Verordnungen motiviert wird [1]. Um diese Anforderungen zu erfüllen, muss beispielsweise der Hausmüll durch aufwändige Sortiervorgänge in seine verschiedenen Stoffklassen aufgeteilt werden.

Ein anderer Bereich, in dem Sortieranlagen zunehmend eingesetzt werden, ist die Nahrungsmittelindustrie. Nahrungsmittel müssen frei von schädlichen Stoffen oder Objekten sein; außerdem wünscht der Kunde ein optimales und reines Produkt. Daher müssen bei der Qualitätskontrolle des Herstellungsprozesses Fremdkörper wie z. B. Verpackungsmaterialien entfernt werden. Des Weiteren spielt bei Nahrungsmitteln die Güte und das Aussehen eine wichtige Rolle, weshalb auch Produkte mit niedriger Qualität erkannt und aussortiert werden.

Einige der genannten Sortieraufgaben werden händisch durchgeführt, wodurch hohe Kosten entstehen und nur eine geringe Prozessgeschwindigkeit erreicht wird. Werden automatische Sortieranlagen eingesetzt, bringen diese den Vorteil, dass sie rund um die Uhr betrieben werden können und eine konstante Qualität liefern. Dadurch lassen sich die Kosten des Sortierprozesses verringern.

Bei der automatischen Sortierung von Schüttgütern bewegt sich das zu sortierende Material beispielsweise auf einem Förderband unter einer Zeilenkamera hindurch (vgl. Abb. 12.1). Das Signal der Kamera wird verarbeitet und die einzelnen Objekte klassifiziert. Anschließend wird mit dem

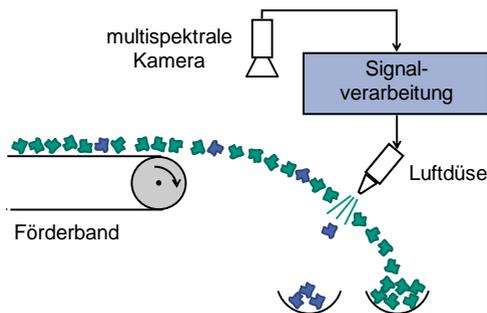


Abbildung 12.1: Automatische Sortieranlage.

Ergebnis eine Ausblaseinheit angesteuert und die unerwünschten Objekte ausgestoßen. Bei einfachen Systemen wird meistens eine Graustufen- oder RGB-Kamera eingesetzt. Diese liefert bei anspruchsvollen Aufgabenstellungen jedoch nicht genügend Information, um ein zufriedenstellendes Sortierergebnis zu erreichen. Durch Hinzunahme eines nicht sichtbaren Spektralbereichs kann die Erkennungsrate erhöht werden.

1.1 Infrarotspektroskopie

Die IR-Spektroskopie wird seit vielen Jahren in der Analytik von Nahrungsmitteln, Kunststoffen und Mineralien eingesetzt [2]. Dabei wird die Lichtabsorption von Materialien untersucht, welche von Atom- und Molekülschwingungen verursacht wird. Diese ist für jedes Material spezifisch, wodurch eine stoffliche Zuordnung des Absorptionsspektrums ermöglicht wird. Besondere Bedeutung hat dabei das Spektrum im Nahinfrarotbereich (NIR), d. h. bei einer Wellenlänge zwischen 800 nm und 2500 nm. In diesem Bereich liegen die Oberton- und Kombinationsschwingungen von Molekülen. Die einzelnen NIR-Absorptionsbanden sind jedoch schwächer ausgeprägt als die Banden der Grundschiebungen, was die Interpretation erschwert. Dafür ist eine Messung im NIR im Vergleich zum mittleren Infrarot schneller durchführbar und unempfindlicher gegenüber Verunreinigungen.

Während bei der klassischen Spektroskopie das Absorptionsspektrum an einem einzigen Ort untersucht wird, erlaubt die hyperspektrale Bildaufnahme eine exakte Zuordnung der räumlichen und spektralen Information. Somit können die Methoden der Spektroskopie auch in Sortieranlagen eingesetzt werden, da hier zu jedem Bildpunkt ein eng abgetastetes Spektrum aufgenommen wird. Hyperspektrale Bildaufnahmen werden seit vielen Jahren in der Fernerkundung zur Klassifikation von Böden, Vegetation und Bebauung genutzt [3]. Außerdem spielen sie in der Agrarwirtschaft eine wichtige Rolle bei der Kontrolle des Pflanzenwachstums und der Ernte [4]. Andere Anwendungen liegen in der Laboranalytik und auch bereits in der Analyse von Produkten auf dem Fließband [5–7].

1.2 Problemstellung

Für den Einsatz hyperspektraler Bilder in Sortieranlagen müssen diese die Anforderungen an Auflösung und Geschwindigkeit erfüllen. Mit aktu-

ellen hyperspektralen Systemen können diese Bedingungen nicht erreicht werden (vgl. Abschnitt 1.3). Durch Reduktion der Messung auf die spektralen Bereiche, welche zur Lösung des Sortierproblems notwendig sind, können die Messung beschleunigt und die Anforderungen erfüllt werden. Eine solche Lösung mit wenigen Infrarot-Zeilenkameras ist günstiger als ein komplettes hyperspektrales System und ermöglicht gleichzeitig eine höhere Bildrate und Auflösung. Eine weitere Möglichkeit zur Verbesserung eines Sortiersystems bietet die Kombination aus herkömmlicher günstiger RGB-Kamera und der Aufnahme von einzelnen Bändern im Infrarotbereich. Es stellt sich nun die Frage, wie diejenigen spektralen Bereiche gefunden werden können, welche zu einer optimalen Trennbarkeit der unterschiedlichen Stoffklassen führen. Dafür gibt es verschiedene Bandselektionsverfahren, die in Abschnitt 2 näher beschrieben werden. Für ein bestimmtes Sortierproblem muss darüber hinaus untersucht werden, wie viele spektrale Bänder, d. h. wie viele Merkmale, für die Sortierung nötig sind.

1.3 Stand der Technik

In aktuellen Sortieranlagen wird das Schüttgut mit einer Geschwindigkeit von 3 – 6 m/s unter einer Zeilenkamera hindurchgeführt. Mit der Bildrate des Kamerasystems lässt sich daraus die Größe eines Bildpunktes bestimmen. Beispielsweise hat ein aktuelles hyperspektrales System, welches im Nahinfrarotbereich eingesetzt wird, eine Bildrate von 120 Hz und liefert dabei Spektren für 256 Bildpunkte. Daraus ergibt sich eine Pixellänge von 2,5 – 5 cm, was bedeutet, dass nur ausgedehnte Objekte richtig klassifiziert werden können. Eine zusätzliche Bildverarbeitung, wie z. B. eine Texturanalyse, ist mit einer solch groben Auflösung nicht durchführbar. In vielen Bereichen wäre diese jedoch von großem Nutzen.

Einen großen Einfluss auf die Auflösung und Geschwindigkeit einer hyperspektralen Bildaufnahme hat auch die Art, wie diese durchgeführt wird. Beim Einsatz einer Zeilenkamera kann zwischen einer Scanner-Apparatur und einem Flächensensor unterschieden werden. Durch einen Scanner wird die Bildzeile abgetastet und das zurückgestreute Licht zeitlich versetzt durch Multiplexer verteilt und in seine spektralen Anteile zerlegt. Dagegen wird bei einem Flächensensor das Licht einer ganzen Zeile durch ein Prisma geleitet und mit dem Flächensensor gleichzeitig die spektrale und räumliche Information der gesamten Zeile gewonnen.

2 Methoden der Merkmalsextraktion

Die Klassifikation von Materialien erfolgt in einem Merkmalsraum, der aus einigen wenigen Merkmalen gebildet wird. In diesem Fall sollen die Signale der optischen Sensoren direkt als Merkmal verwendet werden. Für die Merkmalsextraktion aus hyperspektralen Bildern gibt es eine Vielzahl an Methoden, welche grundsätzlich in zwei Arten unterschieden werden können.

Zum Einen können alle spektralen Bänder (Variablen) verwendet und daraus Merkmale generiert werden, indem Linearkombinationen der Bänder gebildet werden. Ein Überblick und Vergleich verschiedener Algorithmen zu dieser Art von Merkmalsextraktion aus hyperspektralen Daten findet sich in [8]. Das bekannteste Beispiel ist die Karhunen-Loève-Transformation, welche auch Hauptkomponentenanalyse (PCA) genannt wird. Eine einzelne Hauptkomponente bei der PCA setzt sich als Linearkombination aus allen spektralen Bändern zusammen und kann daher nicht physikalisch sinnvoll interpretiert werden. Für den Einsatz in automatischen Sortieranlagen kommt diese Art von Merkmalsextraktion nicht in Frage, da dazu alle Bänder nötig sind und aus in Abschnitt 1.2 genannten Gründen nur einzelne Bereiche aufgenommen werden sollen.

Bei einem anderen Ansatz wird das hyperspektrale Bild genutzt, um bestimmte spektrale Bereiche auszuwählen, welche sich aus benachbarten einzelnen Bändern zusammensetzen. Dieser Vorgang wird als Bandselektion bezeichnet und kann einfach in Hardware implementiert werden, da ein spektraler Bereich durch ein angepasstes optisches Bandpassfilter extrahiert werden kann. Die Bandselektion kann auf verschiedene Arten durchgeführt werden. Das Spektrum kann entweder iterativ aufgeteilt werden [9] oder benachbarte Bänder können verschmolzen werden [10]. Eine weitere Möglichkeit ist die Extraktion der Bänder durch Gewichtungsfunktionen [11]. Diese Gewichtungsfunktionen können als Transmissionsfunktionen der optischen Filter, welche im richtigen Systemaufbau eingesetzt werden, aufgefasst werden und sind daher für die beschriebene Problemstellung vielversprechend. Das Verfahren soll hier näher beschrieben werden.

Die Merkmalsextraktion geschieht durch die Nachbildung optischer Filter mit einer Transmissionsfunktion

$$f(\lambda; c_i, w_i) = \exp \frac{(c_i - \lambda)^2}{2w_i^2} \quad \text{für } i = 1, \dots, d.$$

c_i bezeichnet dabei die mittlere Wellenlänge und w_i bestimmt die Breite der optischen Bandpassfilter. Für jedes Pixel können die d neuen Merkmale aus dem Spektrum $s(\lambda)$ mit der Transformation

$$m_i = \int s(\lambda) q(\lambda) f(\lambda; c_i, w_i) d\lambda \quad \text{für } i = 1, \dots, d$$

berechnet werden. Das Integral bildet die Aufnahme mit einem Sensor mit der Quantenausbeute $q(\lambda)$ und einem davor angebrachten optischen Filter $f(\lambda; c_i, w_i)$ nach. Das heißt, dass die Größe m_i der Intensität entspricht, welche von einem Sensor gemessen werden würde. Der Einfachheit halber wird der Einfluss der Beleuchtung vernachlässigt und von einer über den gesamten Wellenlängenbereich konstanten Beleuchtung ausgegangen. Die Wahl von d passenden Bandpassfiltern kann nun für dieses spezielle Sortierproblem auf die Wahl der Parameter c_i und w_i und die Auswertung der neuen Variablen m_i zurückgeführt werden. Um eine optimale Trennung zu erhalten, müssen die Parameter der Filterfunktion $f(\lambda; c_i, w_i)$ so gewählt werden, dass die Merkmale m_i eine möglichst gute Unterscheidung ermöglichen. Gleichzeitig sollte die Anzahl der Filter d klein gehalten werden, um die Dimensionalität des Klassifizierungsproblems zu begrenzen.

Alle Verfahren haben gemeinsam, dass die Wahl der spektralen Bereiche anhand der Trennbarkeit der Klassen bewertet werden muss. Aus theoretischer Sicht bildet der Bayes-Fehler die untere Grenze des zu erwartenden Klassifikationsfehlers und wäre damit das beste Kriterium, um die Parameterwahl zu bewerten. Der Bayes-Fehler kann allerdings nicht direkt berechnet werden, weshalb andere statistische Werte, wie die Bhattacharyya-Distanz [11] oder die Mahalanobis-Distanz [10] verwendet werden, mit denen sich eine Gütefunktion für die Trennbarkeit zweier Klassen definieren lässt, welche sich auch auf Mehrklassen-Probleme erweitern lässt [12]. Eine andere Möglichkeit ist, die Daten anhand der neuen Merkmale zu klassifizieren und das Ergebnis des Klassifikators z. B. mithilfe des Kreuzvalidierungsverfahrens oder anhand eines Validierungsdatensatzes zu bewerten. Da eine globale Suche nach dem Optimum der Gütefunktion nicht realistisch durchführbar ist, muss auf heuristische Algorithmen, wie z. B. genetische Algorithmen, zurückgegriffen werden.

3 Experimentelle Ergebnisse

Die in Abschnitt 2 beschriebenen Methoden können anhand eines Beispiels aus der Nahrungsmittelsortierung verdeutlicht und bewertet werden. In diesem Fall sollen getrocknete Zwiebeln von Fremdmaterialien wie Steinen oder Verpackungsmaterial getrennt werden. Zunächst wird ein hyperspektrales Bild von den verschiedenen Materialklassen aufgenommen. Abbildung 12.2 zeigt ein RGB-Bild der Materialien und die zugehörigen Spektren im Nahinfrarotbereich. Die hyperspektrale Bild-

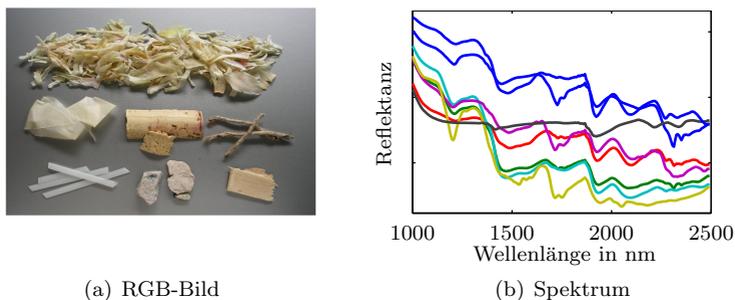


Abbildung 12.2: Getrocknete Zwiebeln und verschiedenes Fremdmaterial (Papier, Kork, Schnur, Plastik, Steine, Papier).

aufnahme wurde mit einem System der Firma Specim im Wellenlängenbereich von 1000 nm bis 2500 nm gewonnen. Die Proben wurden mit einer Halogenlampe beleuchtet. Um die Abhängigkeit des Reflektanzspektrums eines Pixels von der Beleuchtung und der Sensitivität des Sensors zu korrigieren, wurde ein Weißabgleich durchgeführt. Dazu wird eine Aufnahme eines Referenzmaterials, in diesem Fall Polytetrafluorethylen, welches eine gleichmäßige Reflektanz im untersuchten Wellenlängenbereich aufweist, gewonnen. Außerdem wird der Dunkelstrom des Sensorarrays gemessen. Eine zusätzliche Kalibrierung des Spektrographen ist nicht notwendig, da dieser bereits vom Hersteller kalibriert wurde.

Zuletzt werden die einzelnen Pixel den verschiedenen Materialien zugeordnet und diese in unterschiedliche Klassen eingeteilt. Es werden zwei Szenarien untersucht. In einem ersten Versuch bilden die Spektren der Zwiebeln eine Klasse und eine zweite Klasse setzt sich zu gleichen Teilen aus den Spektren der Fremdmaterialien zusammen. Es handelt sich also

um ein Zwei-Klassen-Problem, bei dem nur zwischen Gut- und Schlechtmaterial unterschieden werden soll. In einem anderen Versuch werden fünf gleich große Gruppen von Zwiebel, Kork, Papier, Stein und Papier gebildet und versucht, durch einen Klassifikator die einzelnen Stoffklassen zu erkennen. Für beide Szenarien wird sowohl ein Trainingsdatensatz sowie ein Testdatensatz gebildet.

Mit diesen sortierten Trainingsdatensätzen kann ein überwachtes Bandselektionsverfahren angewandt werden, um einzelne Spektralbereiche auszuwählen, welche eine gute Unterscheidung zwischen den Materialklassen zulassen.

Durch das Verfahren mit parametrisierten Filterfunktionen lassen sich die optischen Filterparameter direkt bestimmen. Da nur eine niedrige Anzahl an Filtern im endgültigen System realisierbar ist, werden im Folgenden genauere Untersuchungen nur für ein, zwei und drei Filter durchgeführt. Als Optimierungsverfahren wird die differentielle Evolution gewählt. Im Zwei-Klassen-Fall dient die Bhattacharyya-Distanz als Gütekriterium, bei mehreren Klassen entsprechend die Jeffreys-Matusita-Distanz [12].

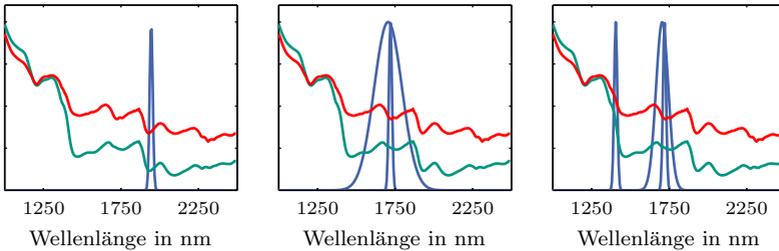


Abbildung 12.3: Filterfunktionen bei zwei Klassen.

Abbildung 12.3 zeigt für das Zwei-Klassen-Szenario die gewonnenen Filterfunktionen, welche die zugehörige Gütefunktion maximieren. Zusätzlich sind die durchschnittlichen Verläufe der Spektren beider Klassen dargestellt.

Zur Evaluation der ausgewählten Filter wird der Testdatensatz mithilfe der quadratischen Diskriminanzanalyse (QDA) klassifiziert [13]. Die erreichten Erkennungsraten sind in Tabelle 12.1 aufgeführt. Bei der Parametersuche kann anstelle der Bhattacharyya- bzw. Jeffreys-Matusita-

Gütekriterium	Klassen- anzahl	Erkennungsrate mit		
		1 Filter	2 Filtern	3 Filtern
Bhattacharyya-Distanz	2	0,79	0,85	0,92
Klassifikations-Fehler (QDA)	2	0,79	0,91	0,91
Jeffreys-Matusita-Distanz	5	0,53	0,97	0,99
Klassifikations-Fehler (QDA)	5	0,57	0,96	0,99

Tabelle 12.1: Erreichte Erkennungsraten bei zwei und fünf Klassen und unterschiedlichen Gütekriterien.

Distanz auch der Klassifikationsfehler der QDA als Gütekriterium herangezogen werden. Die daraus resultierenden Erkennungsraten sind ebenfalls in Tabelle 12.1 zu sehen. Die Ergebnisse mit verschiedenen Gütekriterien sind sehr ähnlich, was bedeutet, dass bei der Optimierung die Bhattacharyya-Distanz verwendet werden kann.

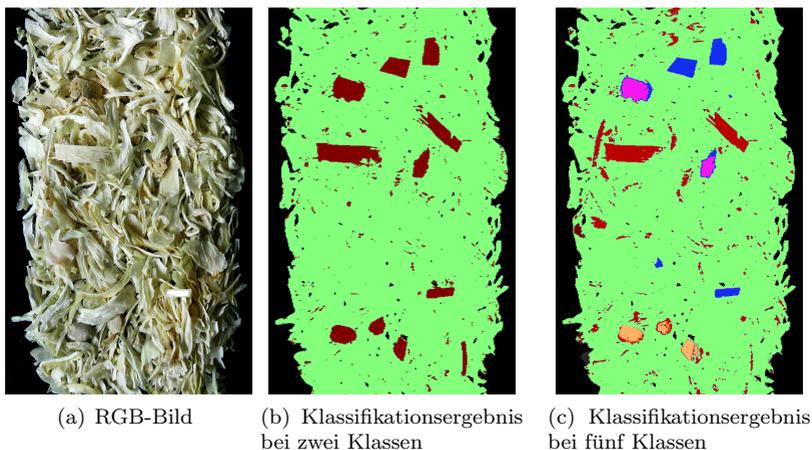


Abbildung 12.4: Klassifikationsergebnis bei einem Testbild mit drei Filtern.

Das Ergebnis der Bandselektion kann an einem weiteren hyperspektralen Testbild von getrockneten Zwiebeln und Fremdmaterialien dargestellt werden. Abbildung 12.4 zeigt ein RGB-Bild der Materialien und die simulierten Sortierergebnisse, die für eine NIR-Zeilenkamera und drei verschiedene optische Filter zu erwarten sind. In diesem Bild werden

alle Fremdstoffe erkannt, doch werden auch einige Pixel, bei denen es sich um Zwiebeln handelt, fälschlicherweise als Fremdmaterial klassifiziert. Um das Ergebnis zu verbessern, können herkömmliche Techniken der Bildverarbeitung eingesetzt werden, welche kleine falsch klassifizierte Bereiche entfernen.

4 Zusammenfassung

Hyperspektrale Bildaufnahmen ermöglichen es, herkömmliche Spektroskopie aus der Analytik mit der Bildverarbeitung, welche in der Automatisierungstechnik eingesetzt wird, zu verknüpfen. Es wurde gezeigt, wie mithilfe der Methoden der Bandselektion die Messdaten auf die notwendige Menge reduziert und dadurch die Anforderungen für den Einsatz in automatischen Sortieranlagen erfüllt werden können.

Die Bhattacharyya-Distanz hat sich dabei als hilfreiches Mittel erwiesen, die Trennbarkeit zweier Klassen zu bewerten. Durch die Erweiterung auf das Mehrklassenproblem mithilfe der Jeffreys-Matusita-Distanz kann eine stoffspezifische Klassifikation durchgeführt werden. Mit der quadratischen Diskriminanzanalyse können gute Erkennungsraten erzielt werden, wobei die Ergebnisse bei einer Klassifikation mit drei Filtern besser sind als bei einem Einsatz von nur zwei Filtern. Eine Klassifikation mit nur einem Filter liefert keine zufriedenstellenden Erkennungsraten.

Durch die vorgestellte Bandselektionsmethode werden in der Regel schmalbandige Bänder bevorzugt ausgewählt. Um auch eine Sortierung von dunklen, stark absorbierenden Stoffen zu ermöglichen, sollten die ausgewählten Spektralbereiche möglichst breit sein, damit viel Licht vom Sensor aufgenommen und ein besseres Signal-zu-Rausch-Verhältnis erreicht wird. Wie die Methode angepasst werden kann, sodass breitere Filter ausgewählt werden und gleichzeitig ein gutes Klassifikationsergebnis ermöglicht wird, ist Gegenstand weiterer Untersuchungen.

Literatur

1. „Richtlinie 2008/98/EG des Europäischen Parlaments und des Rates vom 19. November 2008 über Abfälle und zur Aufhebung bestimmter Richtlinien“, *Amtsblatt der Europäischen Union*, Vol. L 312, Nr. 1, S. 3–30, 2008.

2. P. Williams, *Near-Infrared Technology: In the Agricultural and Food Industries*, 2. Aufl. Amer Assn of Cereal Chemists, 11 2001.
3. A. Goetz, „Three decades of hyperspectral remote sensing of the Earth: A personal view“, *Remote Sensing of Environment*, Vol. 113, S. S5–S16, 2009.
4. M. Zude, Hrsg., *Optical Monitoring of Fresh and Processed Agricultural Crops (Contemporary Food Engineering)*, 1. Aufl. CRC Press, 10 2008.
5. P. Mehl, Y. Chen, M. Kim und D. Chan, „Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations“, *Journal of Food Engineering*, Vol. 61, Nr. 1, S. 67–81, 2004.
6. A. Gomez, Y. He und A. Pereira, „Non-destructive measurement of acidity, soluble solids and firmness of Satsuma mandarin using Vis/NIR-spectroscopy techniques“, *Journal of food engineering*, Vol. 77, Nr. 2, S. 313–319, 2006.
7. D. Ariana, R. Lu und D. Guyer, „Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers“, *Computers and electronics in agriculture*, Vol. 53, Nr. 1, S. 60–70, 2006.
8. P. Paclik, R. Leitner und R. Duin, „A study on design of object sorting algorithms in the industrial application using hyperspectral imaging“, *Journal of Real-Time Image Processing*, Vol. 1, Nr. 2, S. 101–108, 2006.
9. S. Serpico und G. Moser, „Extraction of spectral channels from hyperspectral images for classification purposes“, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 45, Nr. 2, S. 484–495, 2007.
10. P. Withagen, E. den Breejen, E. Franken, A. de Jong und H. Winkel, „Band selection from a hyperspectral data-cube for a real-time multispectral 3CCD camera“, 2001, S. 84–93.
11. S. De Backer, P. Kempeneers, W. Debruyne und P. Scheunders, „A band selection technique for spectral classification“, *IEEE Geoscience and Remote Sensing Letters*, Vol. 2, Nr. 3, S. 319–323, 2005.
12. L. Bruzzone, F. Roli und S. Serpico, „An extension of the Jeffreys-Matusita distance to multiclass cases for feature selection“, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 33, Nr. 6, S. 1318–1321, nov. 1995.
13. T. Hastie, R. Tibshirani, J. Friedman und J. Franklin, „The elements of statistical learning: data mining, inference and prediction“, *The Mathematical Intelligencer*, Vol. 27, Nr. 2, S. 83–85, 2005.

