

Abschlussbericht

Zuwendungsempfänger:

Technische Universität Ilmenau

**PF 10 05 65
98684 Ilmenau**



Förderkennzeichen:

16 IN 0496

Vorhabensbezeichnung:

QualiKorn – Bewertung und innovative Qualitätssicherung von Getreide mit lernfähiger automatisierter Bildanalyse unter Nutzung von spektralen, kontur- und texturorientierten Objektmerkmalen

Laufzeit des Vorhabens: 01.07.2007 bis 30.06.2010

Berichtszeitraum: 01.07.2007 bis 30.06.2010



Projektreffen 2009 in Detmold am MRI/BfEL

Bearbeiter des Abschlussberichtes:

Dr.-Ing. Peter Brückner,
Dr.-Ing. Katharina Anding,
Dr. Ing. Daniel Garten,
Dipl.-Ing. Steffen Lerm,

Verantwortlicher Hochschullehrer:
Projektleiter:

Prof. Dr.-Ing. habil. Gerhard Linß,
Dr.-Ing. Peter Brückner

Bearbeiter im Projekt:

Dr.-Ing. Katharina Anding	(07/07-06/10),	Dipl.-Ing. Martin Dambon	(07/07-06/10),
Dr.-Ing. Daniel Garten	(09/07-06/10),	Dipl.-Ing. Steffen Lerm	(04/08-06/10),
Dr. rer. nat. Torsten Büttner	(07/07-09/09),	Dipl.-Ing. (FH) Marion Zumpf	(07/07-04/08),
Dipl.-Ing. Holger Weißensee	(07/07-03/08),	Dipl.-Ing. Astrid Hildebrandt	(05/08-06/10),
Dipl.-Ing. Timm Muntel	(06/09-06/10),	Dipl.-Ing. Richard Fütterer	(01/10-06/10),
Dipl.-Ing. Rolf Hoffmann	(04/08-05/09),	Dipl.-Inf. Alexander Schlegel	(04/08-09/09),

Gliederung

1. Kurze Darstellung zu

- 1) Aufgabenstellung
- 2) Voraussetzungen, unter denen das Vorhaben durchgeführt wurde
- 3) Planung und Ablauf des Vorhabens
- 4) wissenschaftlichem und technischem Stand, an den angeknüpft wurde, insbesondere
 - a) Status quo
 - b) Angabe bekannter Konstruktionen, Verfahren und Schutzrechte, die für die Durchführung des Vorhabens benutzt wurden
 - c) Angabe der verwendeten Fachliteratur sowie der benutzten Informations- und Dokumentationsdienste
- 5) Zusammenarbeit mit anderen Stellen

2. Eingehende Darstellung

- 1) der Verwendung der Zuwendung und des erzielten Ergebnisses im Einzelnen, mit Gegenüberstellung der vorgegebenen Ziele
- 2) der wichtigsten Positionen des zahlenmäßigen Nachweises
- 3) der Notwendigkeit und Angemessenheit der geleisteten Arbeit
- 4) des voraussichtlichen Nutzens, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans
- 5) des während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordenen Fortschritts auf diesem Gebiet bei anderen Stellen
- 6) der erfolgten oder geplanten Veröffentlichung des Ergebnisses

1. Kurze Darstellung zu

1) Aufgabenstellung

Die Eingangskontrolle einer Getreidepartie erfolgt bisher durch eine manuell-visuelle Besatzanalyse der äußeren Beschaffenheit der Getreide-Anlieferung durch erfahrene Laboranten oder Müllermeister. Die manuelle Besatzbestimmung ist eine sehr zeitaufwändige und subjektive Untersuchungsmethode. Die Aufgabe des Vorhabens bestand in der Entwicklung eines völlig neuen Verfahrens und eines gerätetechnischen Prototyps, welcher über bildanalytische Verfahren die Erkennung und Klassifizierung von einwandfreiem Grundgetreide und den Besatzfraktionen automatisiert durchführt. Dies sollte unter Nutzung spektraler, kontur- und texturorientierter Objektmerkmale durchgeführt werden (automatisierte Besatzanalyse). Im Ergebnis sollte der Anteil der verschiedenen Besatzfraktionen schnell, präzise, objektiv und mit einer hohen Reproduzierbarkeit automatisch ermittelbar sein, um auf Seiten der Erfasser (Landwirte, aufnehmender Getreidehandel, Mühlenwirtschaft,..) und Saatgutvertreiber ein System zur schnellen und zuverlässigen Besatzanteilermittlung und Qualitätslenkung zur Verfügung stellen zu können. Ziele:

- schnelle und reproduzierbare automatische Bestimmung des Anteils der verschiedenen Besatzfraktionen in Weizen und die Dokumentation der Getreidequalität;
- sicherere Datengrundlage als Basis für die Entscheidungen bezüglich der Annahme bzw. Ablehnung von Getreidepartien sowie den zu ergreifenden Maßnahmen der Qualitätslenkung bei der Ernte- und Saatgutaufbereitung;
- Erhöhung der Marktfähigkeit der Ware sowie auch eine Steigerung der Lebensmittelsicherheit und damit letztlich Wettbewerbsvorteile für die Unternehmen.

2) Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Das Projekt wurde als Verbundprojekt zwischen Forschungseinrichtungen und Industriepartnern im Programm InnoNet zur Förderung beantragt. Das Vorhaben konnte in dieser Form nur auf Basis des leistungsstarken Verbundes aus Wissenschaft und Wirtschaft unter Nutzung des spezifischen Knowhows aller Partner und der sich daraus ergebenden Synergieeffekte umgesetzt werden. So konnte eine gemeinsame und auf die Zielgruppen fokussierte Forschung zu neuartigen Verfahren für die innovative Qualitätssicherung von Getreide durch automatisierte Bildanalyse umgesetzt werden, um neue Produkte der innovativen Qualitätsmesstechnik zu entwickeln. Die Kooperation schaffte die Verbindung von Forschungsarbeiten der Bereiche industrielle Bildverarbeitung, Automatisierungstechnik sowie Lebensmittel- und Agrartechnik, welche die Voraussetzung für einen qualitativen Sprung im Bereich der Getreidebewertung, -sortierung und Qualitätssicherung ermöglichte.

Die Beteiligten Partner waren strukturiert in Forschungseinrichtungen, Industriebetriebe, Mühlen und Verbände. Im Einzelnen waren dies:

Forschungseinrichtungen:

- Technische Universität Ilmenau, Ilmenau, Fakultät Maschinenbau, Fachgebiet Qualitätssicherung,
- Bundesanstalt für Ernährung und Lebensmittel, Detmold (jetzt: Max-Rubner-Institut),

Industriebetriebe:

- Brabender GmbH & Co.KG, Duisburg (ausgeschieden zum 30.09.2009),
- Carl Zeiss MicroImaging GmbH, Jena,
- GFE Präzisionstechnik Schmalkalden mbH, Schmalkalden,
- Steinbeis-Transferzentrum Qualitätssicherung und Bildverarbeitung, Ilmenau,

Mühlen:

- Landshuter Kunstmühle C. A. Meyer's Nachf. AG, Landshut,
- Heimatsmühle Maximilian O. Ladenburger, Aalen,

Verbände:

- Verband Deutscher Mühlen, Bonn,
- Bundesverband der Agrargewerblichen Wirtschaft e. V., Bonn,
- Deutsches Mais Komitee, Bonn.

3) Planung und Ablauf des Vorhabens

Im Laufe der Forschungsarbeiten zur Anwendung der industriellen Bildverarbeitung für die Qualitätssicherung von Lebensmitteln hatte sich als ein zu erforschendes neues Aufgabengebiet die automatische Bestimmung der Zusammensetzung von Getreidestichproben herausgestellt. Initiiert wurde das Vorhaben durch das Fachgebiet Qualitätssicherung der Fakultät für Maschinenbau der TU Ilmenau. Die Planung für das Projekt wurde von Mitarbeitern der TU Ilmenau unter Beteiligung des Max-Rubner-Instituts (vor Umbenennung: BfEL) Detmold, der Industriebetriebe, der Mühlen und der Verbände durchgeführt. In der Planungsphase entstand in der intensiven Zusammenarbeit zwischen der TU Ilmenau und dem Max-Rubner-Institut ein detaillierter Ablaufplan, der im Verlaufe des Projekts zielstrebig abgearbeitet wurde.

Ebenso wurden bereits in der Antragsphase eine intensive Abstimmungen mit allen am Projekt Beteiligten durchgeführt. Die Zusammenarbeit wurde im Verlauf des Projektes sehr stark ausgebaut und intensiviert.

Die TU Ilmenau übernahm die Gesamtleitung des Projektes und brachte Erfahrungen in den Bereichen Qualitätssicherung, Bildverarbeitung und Objekterkennung ein.

Das Max-Rubner-Institut (zuvor: BfEL) in Detmold ist seit 40 Jahren in die Untersuchungen, welche im Rahmen der jährlichen Besonderen Ernte- und Qualitätsermittlung (BEE) bei Weizen und Roggen durchgeführt werden, eingebunden. Daher war das MRI geradezu prädestiniert, bei der Ablösung der herkömmlichen rein manuell-visuellen Qualitätssicherung von Getreide durch ein automatisiertes bildanalytisches Verfahren, die Weichen zu stellen, Richtungen und Trends aufzuzeigen, die Normeneinhaltung und somit die Güte des neuen Verfahrens zu validieren und die Beschaffung eines repräsentativen Getreideprobenbestandes zu realisieren.

Die Kompetenzträger der Automatisierungs- und Gerätetechnik im Projekt waren das Steinbeis-Transferzentrum Qualitätssicherung & Bildverarbeitung, die GFE - Präzisionstechnik Schmalkalden mbH sowie die Carl Zeiss Microlmaging GmbH. Dieses Know-how floss in den Bau des Prototyps mit ein.

Aus dem Bereich der agrargewerblichen Wirtschaft waren die Landshuter Kunstmühle, C.A. Meyer's Nachf. AG und die Heimatsmühle Maximilian O. Ladenburger (die eigentlichen Endanwender) in das Gesamtprojekt eng integriert. Sie stellten die Anforderungen an den Prototypen zur automatischen Besatzanalyse aus der Sicht des Anwenders auf, führten Praxistests durch und lieferten manuell analysierte Getreideproben für Vergleichsuntersuchungen. Zur Unterstützung der Interessen der agrargewerblichen Wirtschaft und zur Veröffentlichung an einen breiten Anwenderkreis waren der Verband Deutscher Mühlen e. V., das Deutsche Maiskomitee e. V. und der Bundesverband der Agrargewerblichen Wirtschaft e. V. integriert.

4) wissenschaftlichem und technischem Stand, an den angeknüpft wurde, insbesondere**a) Status quo**

Die Eingangskontrolle einer Getreidepartie erfolgte zuvor durch eine visuelle Prüfung der äußeren Beschaffenheit der Getreide-Anlieferung. Eine Bestimmung des Besatzes wurde durchgeführt, wenn bei der Sichtkontrolle Abweichungen von der Qualitätserwartung erkannt wurden und wenn kontraktlich festgelegte Höchstmengen an Besatz zu überprüfen waren. Die manuelle Besatzbestimmung ist in der EG-VO 824/2000 sowie in den ICC-Standards 102/1 für Weizen und 103/1 für Roggen beschrieben. Die Bestimmung des Anteils der verschiedenen Besatzfraktionen erfolgt, indem nach Absiebung der sehr groben (z.B. Steine) sowie der sehr feinen (z.B. Sand) Verunreinigungen, eine Probe von 50 – 100 g einzelobjektweise von einer Person in Augenschein genommen wird (Zeitaufwand: mindestens 30

min). Damit ist die manuelle Besatzbestimmung eine sehr zeitaufwendige und subjektive Untersuchungsmethode, die höchste Konzentration in der Durchführung erfordert. Dem steht entgegen, dass die Feststellung der äußeren Beschaffenheit in der Praxis oft unter erheblichem Zeitdruck erfolgen muss, insbesondere während der Annahme von Druschgetreide. Bei der visuellen Identifizierung der verschiedenen Besatzfraktionen bleibt es nicht aus, dass fließende Übergänge auftreten und das Ergebnis letztlich auch stark durch die Subjektivität des Prüfers beeinflusst wird. Dieses konnte auch durch die Ergebnisse eines internationalen Ringversuches zur Besatzbestimmung bei Weizen, Roggen und Durum bestätigt werden. Dieser Ringversuch wurde im Jahr 2006 unter Federführung der Bundesforschungsanstalt für Ernährung und Lebensmittel (BfEL) unter Beteiligung von 15 Laboratorien aus 11 Ländern durchgeführt.

Zusammenfassend bleibt festzuhalten, dass die **bisherige manuelle Besatzbestimmung**:

- eine wichtige Untersuchungsmethode bei der Eingangskontrolle der Rohware Getreide sowie bei der Qualitätsbeurteilung von Saatgut darstellt;
- als zum Projektstart rein visuell-manuelle Auslese der Fraktionen, die nicht zum einwandfreien Grundgetreide gehören, Stand der Technik war;
- eine sehr zeitaufwendige Methode ist, die aber oftmals unter hohem Zeitdruck durchgeführt werden muss;
- geschultes und erfahrenes Personal benötigt;
- große Unterschiede (und damit subjektive Unsicherheiten) in den Ergebnissen beinhalten kann, bedingt durch die Subjektivität der Prüfer, sowie
- große Unsicherheiten der Ergebnisse beinhalten kann, bedingt durch eine zu kleine Untersuchungsmenge.

Neben der Besatzanalyse von Getreide kommt vor allem den Mykotoxinen eine besondere Bedeutung zu, da diese äußerst schädliche Auswirkungen auf den Konsumenten haben können. Der Nachweis von Mykotoxinen erfolgt in der Regel mit chemischen (Liquid- oder Gas-Chromatographie mit anschließender Massenspektrometrie), immunologischen (ELISA, RIA) und molekularbiologischen (PCR) Verfahren, welche aufwendig sind und entsprechendes Labor-Equipment benötigen.

Neben der Besatzanalyse und spektrometrischen Analysen sollte im Rahmen des Projektes u. a. untersucht werden, ob man auch anhand von Farbanalysen Rückschlüsse auf Pilzbefall des Getreides und damit auf Mykotoxinbelastung ziehen kann. Diesbezügliche Lösungsansätze könnten aufwendige und teure chemische Analysen in Zukunft ablösen.

Neben einer ausführlichen Literatur-, Patent- und Marktrecherche (Ergebnisse nachfolgend unter b) und c)) wurde auch eine Mühlenbefragung bei mehreren Mühlen vor Ort durchgeführt, um einen Überblick über die gängige Praxis der Umsetzung von Richtlinien und Gesetzen zur Besatzanalyse von Getreide zu bekommen.

Zusammenfassend lässt sich sagen, dass die Besatzanalyse in der Praxis zum Zeitpunkt der Projektlaufzeit nach wie vor durch Siebung und anschließendes manuelles Aussortieren durchgeführt wurde [And 2010b]. Der Zeitaufwand für eine 250 g Probe (Besatzanalyse nach Probenteiler lediglich auf 50 – 100 g) beträgt dabei zwischen 30 und 40 Minuten.

b) Angabe bekannter Konstruktionen, Verfahren und Schutzrechte, die für die Durchführung des Vorhabens benutzt wurden

Aus den Recherchen konnten zwei grundsätzliche Richtungen erkannt werden aus denen sich gegebenenfalls Ansätze zur Lösung der geplanten Aufgaben ableiten ließen.

1. Sortiereinrichtungen mit Kamerasystemen zur Aufbereitung von großen Mengen von Getreide, jedoch mit sehr grober Unterscheidung der Objekte (grobe Klasseneinteilung, z.B. nur hell/dunkel oder eine einfache Farbunterscheidung).
2. Prinzipielle Lösungen und Programmen im Bereiche der Bildverarbeitung zur Erkennung und Unterscheidung von Objekten. Diese waren jedoch allgemein ausge-

richtet und nicht für die Belange der automatisierten Besatzanalyse von Getreide nach den geltenden europäischen Normen spezifiziert.

Der Stand der Schutzrechte wurde analysiert. **Aus der Sichtung aller bestehenden Patente und Marktrechercheergebnisse ließ sich ableiten, dass es kein automatisiertes Besatzanalyseverfahren und Gerät für die Besatzanalyse von Getreide nach EG-VO 824/2000 oder den ICC-Standards 102/1 bzw. 103/1 gab. Für die Lösung dieses komplexen Erkennungsproblems im Rahmen des Forschungsprojektes QualiKorn ergab sich somit nicht die Notwendigkeit der Nutzung vorhandener Schutzrechte.**

c) Angabe der verwendeten Fachliteratur sowie der benutzten Informations- und Dokumentationsdienste

Neben der Patentrecherche wurde eine umfangreiche Sichtung der Fachliteratur durchgeführt. Relevante Quellen zu Beginn der Arbeiten waren Bücher, Zeitschriftenbeiträge und internationale Veröffentlichungen aus den zwei Wissensgebieten des Standes der Technik zur Besatzanalyse von Getreidestichproben und des Standes der Technik der industriellen Bildverarbeitung für die Lösung von Erkennungsaufgaben (Machine Learning).

Literaturrecherche - verwendete Fachliteratur

*** eigene Veröffentlichungen**

Im Bereich der Fachliteratur ergaben sich insbesondere die Vertiefung in prinzipielle Lösungen und Programmen im Bereich der Bildverarbeitung zur Erkennung und Unterscheidung von Objekten, insbesondere von Naturprodukten. Von besonderer Bedeutung waren hier die Bildaufnahme sowie die Algorithmik aus dem Bereich des maschinellen Lernens zu sehen.

- [1] Abmayr, W.: Einführung in die digitale Bildverarbeitung. Stuttgart, Teubner Verlag, 1994.
- [2]* Anding, K.: Bildanalysealgorithmen für die Farb- und Strukturklassifikation von Saat- und Erntegut. Fachgebiet Qualitätssicherung, Technische Universität Ilmenau, Fakultät für Maschinenbau, 2005.
- [3] Antes, S.; Birzele, B.; Prange, A.; Krämer, J.; Meier, A.; Dehne, H.-W.; Köhler, P. (2001): Rheological and breadmaking properties of wheat samples infected with *Fusarium* spp., in: Mycotoxin Research, Vol. 17, No. 1, pp. 76-80.
- [4] Bässmann, H. and Kreyss, J.: Bildverarbeitung Ad Oculos. Berlin, Springer Verlag, 4. Aufl., 2004.
- [5] Besondere Ernte- und Qualitätsermittlung (BEE) 2007, Reihe: Daten-Analysen, Bundesministerium für Ernährung, Landwirtschaft und Verbraucherschutz
- [6] Borgelt, C., Klawonn, F., Kruse, R. and Nauck, D.: Neuro-Fuzzy-Systeme: Von den Grundlagen künstlicher Neuronaler Netze zur Kopplung mit Fuzzy-Systemen. Wiesbaden, Vieweg+Teubner Verlag, 3. Ausgabe, 2003.
- [7] Boser, B., Guyon, I. and Vapnik, V.: A Training Algorithm for Optimal Margin Classifiers. Proceedings of the Fifth Annual Workshop on Computational Learning, 1992.
- [8] Breiman, L.: Random Forests Machine Learning, Vol. 45(1), pages: 5-32, 2001.
- [9] Chen, P.-H., Lin, C.-J. and Schölkopf, B.: A Tutorial on ν -support Vector Machines. Applied Stochastic Models in Business and Industry, Vol. 21 (2), pages: 111-136, 2005.
- [10] Demant, C., Streicher-Abel, B. and Waszkewitz, P.: Industrielle Bildverarbeitung: Wie optische Qualitätskontrolle wirklich funktioniert. Berlin, Springer Verlag, 1998.

- [11] Dexter, J. E.; Clear, R. M.; Preston, K. R. (1996): Fusarium Head Blight: Effect on the Milling and Baking of Some Canadian Wheats, in: Cereal Chemistry, Vol. 73, No. 6, pp. 695-701.
- [12] DIN ISO 5725-1 Genauigkeit (Richtigkeit und Präzision) von Messverfahren und Messergebnissen. Deutsches Institut für Normung (DIN) e.V.
- [13] DIN EN 15587 Getreide und Getreideerzeugnisse - Bestimmung von Besatz in Weizen (*Triticum aestivum* L.), Hartweizen (*Triticum durum* Desf.), Roggen (*Secale cereale* L.) und Futtergerste (*Hordeum vulgare* L.), Europäisches Komitee für Normung (CEN), Juli 2008.
- [14] Duda, R. O., Hart, P. E. and Stork, D. G.: Pattern Classification, A Wiley Publication, 2001.
- [15] Eitrich, T.: Dreistufig parallele Software zur Parameteroptimierung von Support-Vektor-Maschinen mit kostensensitiven Gütemaßen. Fachbereich Mathematik und Naturwissenschaften Bergische Universität Wuppertal, 2007, Zugriff am: 29.01.2007.
- [16] Feng Tan, Xuezheng Fu, Hao Wang, Yanqing Zhang and Bourgeois, A.: A Hybrid Feature Selection Approach for Microarray Gene Expression Data. Computational Science – ICCS 2006, Vol. Part II, LNCS 3992, pages: 678 – 685, 2006.
- [17] Fischer, B., Palm, C., Lehmann, T. and Spitzer, K.: Selektion von Farbtexturmerkmalen zur Tumorklassifikation dermatoskopischer Fotografien 2002, www.phobos.imib.rwthachen.de/lehmann/ps-pdf/BVM_2002-338-341.ps.
- [18] Gareis, M.: Mykotoxine und Schimmelpilze. ForschungsReport-Ernährung-Landwirtschaft-Forsten, 2, pages: 4-5, 1999.
- [19] Guo, D. Y.: Algorithmen zur On-Board-Diagnose von Fahrwerksschäden an Schienenfahrzeugen. Fakultät III - Prozesswissenschaften, Technische Universität Berlin, 2005, http://deposit.ddb.de/cgi-bin/dokserv?idn=977006050&dok_var=d1&dok_ext=pdf&filename=977006050.pdf.
- [20] Guyon, I. and Elisseeff, A.: Feature extraction: foundations and applications, Springer Verlag Berlin, 2006.
- [21] Guyon, I., Weston, J., Barnhill, S. and Vapnik, V.: Gene Selection for Cancer Classification using Support Vector Machines. Machine Learning, Vol. 46, pages: 389–422, 2002.
- [22] Haberäcker, P.: Praxis der digitalen Bildverarbeitung und Mustererkennung. München, Hanser Verlag, 1995.
- [23] Hafner, W.: Segmentierung von Video-Bildfolgen durch Adaptive Farbklassifikationen. München, Herbert Utz Verlag 1999.
- [24] Halcon: Reference Manual - Halcon 8.0.3. MVTec Software GmbH, 2009, www.mvtec.com.
- [25] Hall, M. A.: Correlation-based Feature Selection for Machine Learning. Department of Computer Science, University of Waikato, 1999.
- [26] Harris, Earl Jr: Information Gain Versus Gain Ratio: A Study of Split Method Biases.

- The MITRE Corporation/Washington, 2001.
- [27] Henrion, R. and Henrion, G.: Multivariate Datenanalyse - Methodik und Anwendung in der Chemie und verwandten Gebieten. Berlin, Springer-Verlag, 1995.
- [28] Hotelling, H.: Analysis of a complex of statistical variables into principal components, Journal of Educational Psychology 24, pages: 417-441, 498-520, 1933.
- [29] ICC-Standard Nr. 102/1 Bestimmung des Besatzes bei Weizen. Internationale Gesellschaft für Getreidewissenschaft und -Technologie, 1972.
- [30] ICC-Standard Nr. 103/1 Bestimmung des Besatzes bei Roggen. Internationale Gesellschaft für Getreidewissenschaft und -Technologie, 1972.
- [31] IndustrieverbandAgrar: Mykotoxine: Giftige Belastungen von Lebens- und Futtermitteln. 2009, www.profil.iva.de/umwelt-verbraucher/mykotoxine-giftige-belastungen-von-lebensund-futtermitteln, Zugriff am: 10.10.2009.
- [32] Kohonen, T.: Self-Organizing Maps. Berlin, Heidelberg, New York, Springer Verlag, 3rd edition, 2001.
- [33] Labusch, K.: MaxMinOver: Ein neues iteratives Verfahren zur Supportvektor-Klassifikation mit Anwendungen in der Gesichtserkennung. Institut für Neuro- und Bioinformatik, Universität zu Lübeck, 2004.
- [34] Langenbach, R.: Methoden der Farbbildverarbeitung für die automatische Oberflächeninspektion. Berlin, Mensch und Buch Verlag, 1. Aufl. , 2002.
- [35] Berichte zur Lebensmittelsicherheit 2006 - LEBENSMITTEL-MONITORING. Bundesamt für Verbraucherschutz und Lebensmittelsicherheit, 2006, www.bvl.bund.de, Zugriff am: 23.04.2008.
- [36] LGL_Bayern: Höchstmengenregelungen für Mykotoxine in Lebensmitteln in der Europäischen Union und in Deutschland. Bayerisches Landesamt für Gesundheit und Lebensmittelsicherheit, 2009, www.lgl.bayern.de/lebensmittel/rueckstaende/mykotoxine_hoehchstmengenregelung.htm, Zugriff am: 26.10.2009.
- [37] Liedtke, C.-E. and Ender, M.: Wissensbasierte Bildverarbeitung, Springer-Verlag Berlin Heidelberg New York London Paris Tokyo HongKong, 1989.
- [38]* Linß, G.: Statistiktraining im Qualitätsmanagement, Hanser Verlag, 2006.
- [39]* Mach, M.: Bildanalysealgorithmen für die Formklassifikation von Saat- und Erntegut. Fachgebiet Qualitätssicherung, Fakultät für Maschinenbau, Technische Universität Ilmenau, 2005.
- [40] Mitchell, T. M.: Machine Learning. The Mc-Graw-Hill Companies Inc, 1997.
- [41] Monien, K.: Support Vektor Maschinen als Analyseinstrument im Marketing. Fakultät für Wirtschaftswissenschaften, Universität Bielefeld, 2005.
- [42] Nischwitz, A., Fischer, M. and Haberäcker, P.: Computergrafik und Bildverarbeitung: Alles für Studium und Praxis. Wiesbaden, Vieweg+Teubner Verlag, 2. Auflage, 2007.
- [43] Pompl, R., Bunk, W., Horsch, A., Stolz, W., Abmayr, W., Brauer, W., Gläßl, A. and Morfill, G.: MELDOQ: Ein System zur Unterstützung der Früherkennung des malignen

- Melanoms durch digitale Bildverarbeitung. Bildverarbeitung für die Medizin (2000), Reihe Informatik aktuell, pages: 234-238, 2000.
- [44] Profil Online - Magazin für Pflanzenschutz, Pflanzenernährung, Schädlingsbekämpfung und Biotechnologie, <http://www.profil.iva.de/>, Zugriff am: 16.09.2004.
- [45] Richter, W., Schuster, M., Tischner, H., Zimmermann, G., Doleschel, P., Beck, R. and Lepschy von Gleissenthall, J.: Schimmelpilze und Mykotoxine in Futtermitteln Vorkommen, Bewerten, Vermeiden, Länderübergreifende Zusammenarbeit der Landesanstalten für Landwirtschaft. Gemeinsame Beratungsunterlage der Landesanstalten für Landwirtschaft der Bundesländer Baden Württemberg, Bayern, Sachsen und Thüringen, 2005, www.lfl.bayern.de/ite/futterkonservierung/12418/linkurl_0_2.pdf.
- [46] Rodemann, B.: Mykotoxine im Getreide- Eine Gefährdung für die Nahrungsmittelproduktion/Pflanzenschutz steht vor höchsten Anforderungen. ForschungsReport-Ernährung-Landwirtschaft-Forsten, 2, pages: 6-9, 1999.
- [47] Runkler, T. A.: Information Mining: Methoden, Algorithmen und Anwendungen intelligenter Datenanalyse. Wiesbaden, Vieweg Verlag, 2000.
- [48] Schneider, G.: Evolutionäre Optimierung eines biologisch motivierten visuellen Objekterkennungssystems. Technische Fakultät Universität Bielefeld, 2004.
- [49] Schölkopf, B. and Smola, A. J.: Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond, MIT Press, 2001.
- [50] Schölkopf, B., Smola, A. J., Williamson, R. and Bartlett, P.: New support vector algorithms. In: Neural Computation 12 (2000), 2000, pages: 1083-1121.
- [51] Schöneburg, E., Heinzmann, F. and Feddersen, S.: Genetische Algorithmen und Evolutionsstrategien, Bonn, Addison-Wesley-Verlag, 1. Aufl., 1994.
- [52] Seibel, W.: Warenkunde Getreide-Inhaltsstoffe, Analytik, Reinigung, Trocknung, Lagerung, Vermarktung, Verarbeitung. Bergen, Agrimedia GmbH, 2005.
- [53] Seitz, L. M.; Bechtel, D. B. (1985): Chemical, physical, and microscopical studies of scab-infected hard red winter wheat, in: Journal of Agriculture and Food Chemistry, Vol. 33, pp. 373-377.
- [54] Setino, R. and Liu, H.: Chi²: Feature selection and discretization of numeric attributes. In Proceedings of the Seventh IEEE International Conference on Tools with Artificial Intelligence, 1995.
- [55] Sima, C. and Dougherty, E. R.: The peaking phenomenon in the presence of feature-selection. Pattern Recognition Letters, Vol. 29 (2008), pages: 1667–1674, 2008.
- [56] Sima, C. and Dougherty, E. R.: The Peaking Phenomenon Revisited: the Case with Feature Selection. International Workshop on Genomic Signal Processing and Statistics, GENSiPS 2008. IEEE Phoenix Arizona, 2008.
- [57] Vapnik, V.: The Nature of Statistical Learning Theory. New York, Springer Verlag, 1995.
- [58] VERORDNUNG (EG) Nr. 824/2000 DER KOMMISSION über das Verfahren und die Bedingungen für die Übernahme von Getreide durch die Interventionsstellen sowie die Analysemethoden für die Bestimmung der Qualität, 19. April 2000.

- [59] Wang, X., Wu, S., Li, Q. and Wang, X.: v-SVM for Transient Stability Assessment in Power Systems. Autonomous Decentralized Systems, 2005. ISADS 2005. Proceedings, pages: 356-363, 2005.
- [60] Weidenbörner, M. (2001): Encyclopedia of Food Mycotoxins, Springer, Heidelberg.
- [61] Weissler, G. A.: Einführung in die industrielle Bildverarbeitung. Poing, Franzis Verlag, 2007.
- [62] Witten, I. H. and Frank, E.: Data Mining - Praktische Werkzeuge und Techniken für das maschinelle Lernen. München Wien, Carl Hanser Verlag 2001.
- [63] Wittenberg, T., Neubauer, K., Küblbeck, C., Permanyer, I. und Schmidt, R.: Automatische Tumorerkennung bei unterschiedlichen Organen mittels Berechnung und Klassifikation von Texturmerkmalen. Bildverarbeitung für die Medizin, Algorithmen - Systeme - Anwendungen, Workshops vom 4. bis 6. März 2001 in Lübeck, 2001.

Patent- und Marktrecherche - benutzte Informations- und Dokumentationsdienste

Gesucht wurde nach Patenten in 40 wesentlichen Industrieländern und nach Veröffentlichungen über EP und WO [Wag 2007].

Folgende Datenbanken wurden zur Patentrecherche verwendet:

- WPIDS – umfasst ca. 40 wichtige Industrieländer + EP und WO Patente ab 1974
- IFIPAT – umfasst US Patente und US Geschmacksmuster ab 1963
- JAPIO – umfasst ungeprüfte japanische Patente ab 1976

Zur Recherche wurden die in Tabelle 1 beschriebenen Patentklassen verwendet [Wag 2007].

Tabelle 1: Verwendete Patentklassen

<i>Patentklassen</i>	<i>Beschreibung</i>
B02B 1/...	Aufbereiten von Getreide (zum Mahlen oder für nahe liegende Verfahren)
B02B 5/...	Kornbehandlung (reinigen, sortieren, begutachten)
B02B 7/...	Hilfseinrichtungen (Zuführ- oder Entleereinrichtungen)
B07B...	jegliche Art von Sortieren von Schüttgut in Abhängigkeit von dessen Materialeigenschaft
A01C 1/...	Umfasst sämtliche Patente, die sich mit der Saat- und Saatgutvorbereitung befassen (mechanische und elektrische Behandlung, Keimzellen, beizen etc.)
G01N 15/...	Untersuchung von Größen diverser Teilchen
G01N 21/...	verschiedene optische Messverfahren, wobei der Schwerpunkt auf die verschiedenen Beleuchtungen gesetzt ist
G01N 33/...	Untersuchungsmethoden von verschiedensten Materialien, die von vorhergehenden G01N x/x Klassen nicht betrachtet wurden
H04N...	sämtliche Patente welche sich mit Bildübertragung in jeglicher Ausführung beschäftigen
G06K...	Aufbereitung von Bildsignalen (Bildverarbeitung und Bilderkennung in sämtlichen Varianten)
G06T...	Aufbereitung von Bildsignalen (Bilderzeugung und Bildcodierung in sämtlichen Varianten)

Im Ergebnis der über 2 Jahre (2006 – 2007) fortgeführten Patentrecherche war festzustellen, dass sich die recherchierten patentierten Lösungen durchweg alle hinreichend von dem geplanten Verfahren zur Saatgutanalyseeinrichtung unterscheiden und dass sie den Anforderungen des Forschungsvorhabens bzgl. der Klassifikation aller Besatzklassen nach europäischen Normen nicht genügen [And 2010b], [Wag 2007].

5) Zusammenarbeit mit anderen Stellen

Bereits in der Vorbereitung des Projektes erfolgte eine enge Zusammenarbeit mit den am Projekt beteiligten Partnern.

Enger Informationsaustausch, Feedback und Anregungen zur Anwendung und Erweiterung des Besatzanalyseverfahrens fanden zwischen den beteiligten Mühlenbetrieben und Verbänden statt, welche Ihre Sicht seitens der verschiedenen Getreide- und Ölfruchtsorten einbrachten.

Neben den beteiligten Projektpartnern kamen Kontaktaufnahmen sowie ein Informationsaustausch mit den nachfolgend genannten Firmen zustande:

- SÜGEMI - Südthüringer Getreide und Mischfutter GmbH in Themar, Herrn Pfeffer,, Geschäftsführer,
- N.L. Chrestensen Erfurter Samen- und Pflanzenzucht GmbH in Erfurt, Herrn Dr. Blüthner, Züchtung und Saatgut,
- GEKRA - Getreide und Kraftfutter GmbH in Querfurt, , Herrn Gerd Krebs, Geschäftsführer.

2. Eingehende Darstellung

1) der Verwendung der Zuwendung und des erzielten Ergebnisses im Einzelnen, mit Gegenüberstellung der vorgegebenen Ziele

Für die Annahme von Getreide, einem unserer wichtigsten Nahrungsmittel, in Mühlen und Silobetrieben existieren strenge Qualitätskriterien, die sich einteilen lassen in:

- (1) Verfahren zur Bestimmung der Backeigenschaften,
- (2) Feststellung der Probenzusammensetzung durch Besatzanalyse,
- (3) Bestimmung des Gehaltes an pilzschadenbedingten Giftstoffen.

Für die Bestimmung der Backeigenschaften (1) des Getreides bezüglich der späteren Verwendung in Backerzeugnissen, wie Klebergehalt, Fallzahl u. a., gibt es eine Reihe eingeführter Laborverfahren und Geräte am Markt.

Die Automatisierung der Besatzanalyse (2) war Hauptgegenstand der Forschung im Projekt QualiKorn. Hier wurden wichtige wissenschaftlich technische Ergebnisse erreicht, die eine unmittelbare Überführung in die Wirtschaft erlauben, um den Vorgang der Besatzanalyse in den Mühlen und Silobetrieben zu revolutionieren.



Abbildung 1: Bestandteile einer Weizenprobe mit Besatz

Der bisherige Ist-Zustand bei der Annahme von Getreide ist die aufwendige manuelle Besatzanalyse durch geschultes Laborpersonal. Gerade bei der Getreideannahme in der Erntezeit hat die Begutachtung der Ware schnell zu erfolgen. Hier bedarf es einer schnellen und objektiven Entscheidung. In diesem Zusammenhang sind manuelle Verfahren, die einen hohen subjektiven Entscheidungsanteil enthalten, wegen kleiner Probenumfänge mit niedriger statistischer Sicherheit behaftet und die sehr lange Zeit in Anspruch nehmen, denkbar ungünstig.

Die Automatisierung der manuellen Besatzanalyse erfordert die Abbildung eines umfangreichen Expertenwissens im Bereich der Getreideanalytik (ausgebildeter Laborant, Müller- oder Silomeister) auf ein intelligentes Erkennungssystem. Dies erforderte die Klassenbildung aller möglicher Objekte einer Getreidestichprobe der zu untersuchenden Getreideart als sogenannte Wissensbasis (**Meilenstein 02 – Klassenbildung**).

Um den Vorgang der manuellen Besatzanalyse zu automatisieren und damit wesentlich zu verbessern, wurde im Jahr 2007 mit dem Start des Forschungsprojektes QualiKorn begonnen, um auf der Grundlage neuester fortschrittlicher Methoden der industriellen Bildverarbeitung eine Automatisierung der Besatzanalyse zu ermöglichen. Tabelle 2 zeigt den Vergleich der manuellen und der automatisierten Besatzanalyse.

Tabelle 2: Vergleich der manuellen und der automatisierten Besatzanalyse

	Manuelle Besatzanalyse	Automatisierte Besatzanalyse
Probenumfang	50g – 100g	250g – 500g
Dauer der Analyse	30min – 45min	5min – 10min
Bewertung	subjektiv	objektiv

Die Forschungsarbeiten führten zu wesentlichen neuartigen wissenschaftlich-technischen Erkenntnissen, die einen vollständig automatisierten Prozess der Besatzanalyse ermöglichen. Die automatisierte Analyse erfolgt in drei Stufen: Annahme, Vorbehandlung und Besatzbestimmung. Das Schema in Abbildung 2 gibt dieses Prinzip wieder. Die Annahme bzw. die Probenentnahme erfolgt entsprechend den gesetzlich festgelegten Prozeduren [13], [29], [30], [58]. Diese können teilweise durch firmenspezifische Verfahren ergänzt werden.

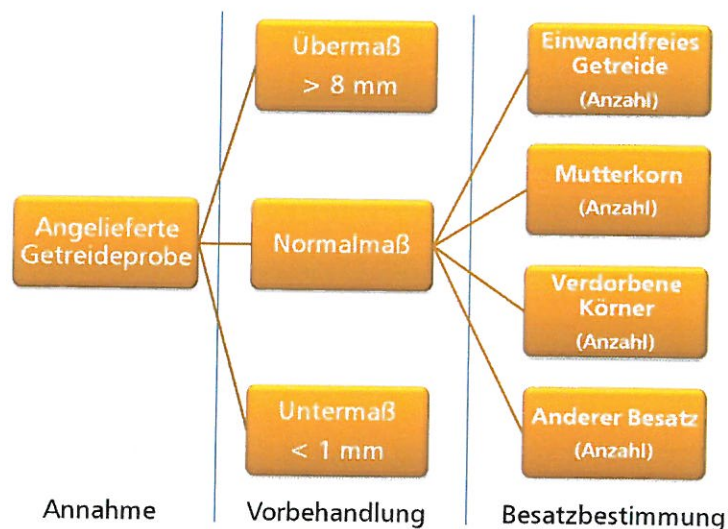


Abbildung 2: Prinzipieller Ablauf der automatisierten Analyse

Neuartige mechanisch-optische Lösung zur dynamischen Bildaufnahme natürlicher Objekte

Zur objektiven Erkennung ist es notwendig, das Messgut automatisch zu dosieren, zu fördern und zu separieren. Dazu ist eine Festlegung auf minimale und maximale Abmessungen technisch notwendig. Für die Besatzanalyse wird ein Bereich von 1 bis 8 mm als relevant angesehen. Kleinere Objekte (z. B. Sand, organische Faserreste) werden im Prozessschritt der Vorbehandlung durch Luftabscheidung abgeschieden. Durch Siebung werden größere Bestandteile (z. B. Ährensteile, lange Strohhalme) im gleichen Schritt entfernt. Sie werden aufbewahrt und stehen bei Bedarf für die Gesamtprobenbilanz zur Verfügung.

Im Ergebnis der Vorbehandlung besteht das Messgut aus unterschiedlich, natürlich geformten Objekten von sehr brüchig bis fester Zusammensetzung im definierten Größenbereich, wie einzelne Detailausschnitte aus Abbildung 3 veranschaulichen.



Abbildung 3: Beispiele für Objekte einer Getreideprobe (aus Abbildung 1)

Im Vergleich zu relativ gleichmäßig ausgeprägten Schüttgut, wie Kunststoffgranulat musste für den Transport und das Dosieren des vorliegenden stark inhomogenen Schüttgutes ein System gefunden, untersucht und weiterentwickelt werden, welches einfach herstellbar ist, keine Veränderung des Messgutes durch mechanische Beanspruchung hervorruft und eine vollständige Separierung bzw. Zuführung zum Bildverarbeitungssystem in festgelegter Geschwindigkeit ermöglicht. Die größte Herausforderung lag darin, die etwa 12000 Objekte des Messgutes (95% Weizen), das einem Probenumfang von etwa 500 g entspricht, ohne mechanisches Verhaken oder Blockieren einzeln an der Farbkamera des Bildverarbeitungssystems in bestimmter Lage vorbeizuführen. Es wurde dazu ein Variantenvergleich der Systeme zum Schüttguttransport durchgeführt.




Abbildung 4: Hochgeschwindigkeitsaufnahmen der Weizenprobe auf einer Fördereinrichtung

Dieser Vergleich beinhaltete umfangreiche, wissenschaftliche Experimente bei denen beispielsweise eine Hochgeschwindigkeitskamera eingesetzt wurde, um die Eigenbewegung einzelner Objekte auf der Fördereinrichtung festzustellen, wie Abbildung 4 exemplarisch zeigt.



Abbildung 5: Dosier- und Transporteinheit zur zwangsfreien Separation

Basierend darauf wurde sich für ein System aus Einfüllbehälter mit speziell geformter Geometrie zur Dosierung, einem antistatischen Förderband mit adaptiertem Volumenstromteiler zum Transport und Separation der Messobjekte entschieden (**Meilenstein 01 - Konzept Hardware** ✓). In Abbildung 5 ist das realisierte, mechanische System in Funktion dargestellt. Wie zu erkennen ist, werden alle Objekte ohne Staubildung für die Bildaufnahme voneinander getrennt. Danach erfolgt die Besatzbestimmung auf der Grundlage modernster Farbbilderfassung mit spezifischen intelligenten Erkennungsalgorithmen. Das technische Grundprinzip für die automatisierte Besatzanalyse besteht in der Bildaufnahme aus einer CCD- Farbzeilenkamera, welche die Objekte im freien Fall oder alternativ auf einem mit konstanter Geschwindigkeit laufenden Band aufnimmt (**Meilenstein 03 – Bildaufnahme** ✓). Zur Beleuchtung hat sich eine Kombination aus Auflicht und Durchlicht als zweckmäßig erwiesen. Das Grundprinzip kann durch Einsatz einer zweiten CCD-Kamera mit dem zugehörigen Beleuchtungssystem ausgebaut werden. Damit könnten Vorder- und Rückseite der Objekte in die Entscheidung einbezogen werden.

Der umgesetzte Versuchsaufbau zur automatisierten Besatzanalyse ist in Abbildung 6 dargestellt. Die Farbzeilenkamera nimmt dabei jedes Einzelobjekt des Messguts im Bereich des sichtbaren Lichtes in drei Farbkanälen: Rot, Grün und Blau (RGB) auf.




Abbildung 6: Versuchsaufbau Prinzip „Freier Fall“ zur Bestimmung der Erkennungsraten bei der Besatzanalyse

Echtzeitfähige Verfahren zur fehlerfreien Segmentierung von Getreidekörnern und Besatz unter Datenreduktion auf informationsrelevante Anteile

Mit der **Bildaufnahme** beginnt ein mehrstufiger Prozess der Erkennung der einzelnen Objekte deren Reihenfolge die Abbildung 7 verdeutlicht.



Abbildung 7: Signalfluss der Objekt-Erkennung

Die Segmentierung dient als Präprozess zur Trennung der zu klassifizierenden Objekte von leeren, informationsirrelevanten Bildinhalten (Hintergrund). Es werden aus den gesamten Bilddaten nur diejenigen Bereiche extrahiert, in denen sich tatsächlich Objekte befinden. In dieser Vorverarbeitungsstufe muss vor allem darauf geachtet werden, dass die ausgeschnittenen Objekte vollständig sind. Dieser wichtige Schritt reduziert den Datenfluss dramatisch um ca. 95%, da alle Bereiche, in denen keine relevanten Informationen enthalten sind, für die weitere Verarbeitung verworfen werden können.

Für eine Klassifikation von Objekten müssen alle Objekte voneinander getrennt als Einzelbilder vorliegen. Diese Einzelbilder müssen aus dem Gesamtbild mit allen Objekten generiert werden. Dabei soll im Einzelbild kein Teil eines Objektes fehlen und fälschlicherweise kein Teil eines anderen Objektes enthalten sein. Weiterhin muss der Algorithmus auf dem von einer Zeilenkamera generierten Endlosbild beliebig große Objekte (entsprechend den technischen Rahmenbedingungen) in Echtzeit ausschneiden können.

In verschiedenen Vorversuchen wurden mehrere Algorithmen für die Segmentierung zusammen liegender und teils angrenzender Objekte getestet. Überlappende Objekte sind generell ungünstig, da auch durch das Segmentieren der durch die Überlappung verdeckte Bereich nicht wiederhergestellt werden kann und diese Information somit verloren geht. Bei diesen Vorversuchen wurden Algorithmen entworfen, die bei aneinander grenzenden Objekten die

Punkte ermitteln, an denen das Bild „zerschnitten“ werden muss, um zwei Objekte daraus zu extrahieren. Dabei wurde festgestellt, dass kein fehlerfrei funktionierender Algorithmus verfügbar war oder generiert werden konnte. Selbst das menschliche Auge ist im Kamerabild häufig nicht in der Lage zu unterscheiden, welche Teile des Bildes zwei Objekte oder ein zusammengehörendes Objekt darstellen. Dies trifft insbesondere auf Körner mit Spelze und Stängelresten zu. Da solch ein Algorithmus die benötigte Rechenzeit für die Segmentierung deutlich vergrößert, ist es eine deutlich günstigere Herangehensweise, die Objekte schon vor der Bildaufnahme zu vereinzeln, wodurch sich die Segmentierung auf die Trennung der Objekte vom Hintergrund beschränkt. Es ist möglich, dass in den Getreideproben auch sehr dunkle Objekte (Raps, bestimmte Unkrautsamen und Steine) enthalten sind. Nach Farbanalyse über das Spektrum dieser Bestandteile wurde festgelegt, eine Segmentierung vor hellem Hintergrund zu realisieren.

Der neue Algorithmus arbeitet dabei zeilenbasiert (vorwärtsgerichtet), d. h. jede aufgenommene Zeile wird verarbeitet, gefundene Objektbereiche sofort zwischengespeichert und dann mit der nächsten Zeile fortgesetzt. Da so nie auf zurückliegende Zeilen zugegriffen werden muss, wie dies bei Auswertung von Matrixkamera-Bildern üblich ist, kann problemlos ein Endlosbild mit beliebig großen Objekten verarbeitet werden.

Das Ausschneiden der Zeilenbereiche basiert auf einem einfachen und sehr schnellen Schwellwertalgorithmus, welcher somit auch in eine Vorverarbeitungshardware übertragen werden kann. Dabei wird aus den Farbkanälen mittels Wichtung ein Grauwert im Bereich von 0 bis 255 berechnet, der mit dem Schwellwert verglichen wird. So wird für jeden Pixel festgelegt, ob er zum Hintergrund oder zu einem Objekt gehört. Verschiedene Objekte aus den Getreideproben werden im Kamerabild sehr hell dargestellt (z. B. Hafer, bestimmte Steine, besonders Spelzen). Es hat sich gezeigt, dass eine Grauwertberechnung entsprechend dem HSI-Modell einige Bereiche dieser hell dargestellten Objekte ausblendet. Da die untersuchten Objekte (mit Ausnahme der Steine) nur geringe Anteile im Blau-Kanal des Farbbildes haben, wurden die Wichtungsfaktoren so gesetzt, dass nur der Blaukanal zum Segmentieren verwendet wird.

In einer zweiten Stufe werden die Objektbereiche zu Objekten zusammengesetzt. Dieser Algorithmus sucht nach Überlappungsbereichen und fügt dann die Daten zu Objektfragmenten zusammen. Dabei wird ebenfalls kontrolliert, ob sich Fragmente überlappen, die dann wiederum zu einem größeren Fragment zusammengeführt werden. Wenn bei einem Fragment nach einer festgelegten Anzahl von Zeilen (z. B. nach einer Zeile) nichts mehr hinzugefügt werden kann, wird das Fragment als abgeschlossen betrachtet und als Objektbild gespeichert. Ausgangsbild und Ergebnis der Segmentierung sind in Abbildung 8 dargestellt.




Abbildung 8: Segmentierung des Bildes zur Erzielung von „Einzelkornbildern“

Der Vorteil der Segmentierung in zwei Stufen besteht darin, dass ein sehr einfacher und schneller Algorithmus die Vorverarbeitung der großen Datenmenge des Kamerabildes übernimmt und ein zweiter aufwendigerer Algorithmus auf deutlich verkleinelter Datenmenge das Zusammenfügen und Filtern durchführt. Der erste Teil des Algorithmus kann prinzipiell zur Beschleunigung der Datenverarbeitung und Sicherung der Echtzeitfähigkeit bei Steigerung

der Bildaufnahmegeschwindigkeit in Hardware-Module (Signalprozessoren, intelligente Kameras etc.) integriert werden.

Neuartige Algorithmen zur Merkmalsextraktion und Klassifikation für Objekte schwer trennbarer Objektklassen

Die Merkmalsextraktion bildet den nächsten Schritt bei dem die einzelnen Merkmale bestimmt werden. Für die Unterscheidung werden die Farb-, Form- und Texturmerkmale der Objekte herangezogen. Die Kombination ergibt einen Merkmalsvektor aus ca. 200 Merkmalswerten, welche für jedes Objekt berechnet werden. Voraussetzung für einen erfolgreichen Prozess des Einlernens ist die Verfügbarkeit einer ausreichenden Menge von Objekten in den einzelnen Klassen (einwandfreies Getreide, pilzgeschädigte Körner,...). Diese wurden in Kooperation mit Mühlen in Deutschland (hauptsächlich Partnermühlen) und mit dem Max-Rubner-Institut in Detmold aus den Ergebnissen vorangegangener Ernten gewonnen. Auf der Grundlage dieser Proben konnte eine umfangreiche Datenbasis für Weizen erstellt werden.

Die Kamera liefert die Farbwerte in Form von 3 Grauwertkanälen (RGB). Für Klassifikationsaufgaben ist jedoch die Verwendung des HSI-Farbraumes zweckmäßiger. Die Umrechnung erfolgt mit folgender Formel [1]:

$$\begin{bmatrix} M_1 \\ M_2 \\ I_1 \end{bmatrix} = \begin{bmatrix} \frac{2}{\sqrt{6}} & -\frac{1}{\sqrt{6}} & -\frac{1}{\sqrt{6}} \\ 0 & \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

Die Umwandlung in Zylinderkoordinaten erfolgt dann über die Gleichungen [1]:

$$\begin{aligned} H &= \arctan(M_1 / M_2) \\ S &= \sqrt{M_1^2 + M_2^2} \\ I &= I_1 \sqrt{3} \end{aligned}$$

Die Merkmalsextraktion erfolgt ausschließlich auf den Bilddaten im HSI-Farbraum. So wird zum Beispiel jeweils für den H-Kanal (hue), den S-Kanal (saturation) und den I-Kanal (intensity) das Histogramm $rel[i]$ berechnet, aus dem sich unter anderem folgende Werte ableiten lassen [24]:

$$Entropy = -\sum_0^{255} rel[i] * \log_2(rel[i])$$

$$Anisotropy = \frac{\sum_0^k rel[i] * \log_2(rel[i])}{Entropy}$$

wobei: $rel[i]$ Histogramm der relativen Grauerhäufigkeiten

i Grauwert des Eingabebildes (0..255)

k kleinstmöglicher Grauwert mit $\sum_0^k rel[i] \geq 0,5$.

Ein weiteres wichtiges Kriterium für die Unterscheidung der Probenbestandteile ist die Textur. Hier hat sich die Berechnung der Coocurrence-Matrix und Ableitung der folgenden Merkmale [24] als besonders gut geeignet und effizient erwiesen:

$$\text{Energy} = \sum_{i,j=0}^{\text{width}} c_{ij}^2 \quad \rightarrow \text{Maß für Bildhomogenität,}$$

$$\text{Correlation} = \frac{\sum_{i,j=0}^{\text{width}} (i-u_x)(j-u_y)c_{ij}}{s_x s_y} \quad \rightarrow \text{Maß für die Grauwertabhängigkeit,}$$

$$\text{Homogenicity} = \sum_{i,j=0}^{\text{width}} \frac{1}{1+(i-j)^2} c_{ij}$$

$$\text{Contrast} = \sum_{i,j=0}^{\text{width}} (i-j)^2 c_{ij} \quad \rightarrow \text{Maß für die Größe der Intensitätsunterschiede.}$$

Durch die Extraktion der Randregion des Objektes mittels morphologischer Operationen und Mengenoperationen mit anschließender Berechnung der Merkmale:

1. Pixelanzahl,
2. Mittelwert der Grauwerte je HSI-Kanal,
3. Varianz der Grauwerte je HSI-Kanal

konnten schnell berechenbare Merkmale mit einer hohen Diskriminanzfähigkeit gefunden werden [Gar 2011].

Für die Merkmalsextraktion wird zum Teil auf das Programm HALCON (Version 8.0) zurückgegriffen. Für eine optimale, die Klassenspezifika berücksichtigende, Trennung der Getreidebestandteile wurden insgesamt weit über 300 Bildmerkmale einzeln und in Kombination untersucht. Die gewählte Merkmalsmenge setzt sich sowohl aus einfachen Grauwertstatistiken im HSI-Farbraum, Histogramm-Merkmalen, geometrischen Momenten der Randkontur als auch aus komplexen Texturmerkmalen, welche z. B. durch die Anwendung von Gabor-Filtern oder adaptierten Texturfiltern gewonnen werden, zusammen. Ein speziell angepasstes Grauwert-Histogramm, welches das Auftreten bestimmter Grauwertkombinationen im HSI-Farbraum berücksichtigt anstatt die drei Grauwertkanäle nur einzeln zu betrachten, erlaubte allein schon eine Trennung der Probenbestandteile mit annähernd 80% Genauigkeit. Besonders wichtig ist hierbei die Abstimmung der Merkmale auf den zu verwendenden Klassifikator. Dies erfolgte mit modernen Algorithmen der Merkmalsbewertung, welche speziell für die Verwendung mit einer hohen Anzahl an Lerndaten ausgewählt und adaptiert wurden. Durch umfangreiche Untersuchungen konnte hier eine optimale Merkmalsmenge bestehend aus rund 200 Merkmalen gefunden werden. Hierfür wurde jedes einzelne Merkmal mit einem Score bewertet, wodurch sich eine definierte Reihenfolge der Merkmale ergibt. Die Bewertung basiert auf der Entropie $H(C)$ für die Objektklasse C [26]:

$$H(C) = \sum_{c \in C} p(c) \cdot \log_2 p(c)$$

Die bedingte Entropie für Klasse C und das Merkmal F ergibt sich wie folgt:

$$H(C|F) = \sum_{f \in F} p(f) \sum_{c \in C} p(c|f) \cdot \log_2 p(c|f)$$

Damit lässt sich der Informationsgewinn (Information Gain) [40] für das Merkmal F berechnen nach:

$$IG_i = H(C) - H(C|F_i)$$

Nun kann durch sukzessive Wegnahme der am schlechtesten bewerteten Merkmale und Schätzung der Erkennungsrate in Kombination mit einem **Support-Vektor-Maschinen-Klassifikator** eine optimale Merkmalsmenge gefunden werden. Da es bei Reduktion der Merkmalsmenge ab ca. 200 verbleibenden Merkmalen zu einem monotonen Abfall der Erkennungsrate kommt, kann man hier auf die gefundene optimale Merkmalsmenge schließen (Abbildung 9). Für das Training des Klassifikators und die Validierung des Verfahrens wurden mehr als 20.000 vorklassifizierte Datensatzbeispiele verwendet, um eine statistisch sichere Aussage zu treffen (**Datenbasis Meilenstein 02**). Wechselwirkungen mit der vorgelagerten Bildaufnahme (Auflösung der aufgenommenen Bilder, Beleuchtung usw.) und dem nachgelagerten Klassifikator wurden ebenfalls untersucht. Im Ergebnis konnte die Bildaufnahmeeinheit im Hinblick auf Durchsatz und Genauigkeit optimiert werden. Ergebnisse aus den Untersuchungen flossen ebenfalls in die Parameteradaption und Art des in der Verarbeitungskette nachgelagerten Klassifikators ein. Alle Untersuchungen zu den Objektmerkmalen wurden auf einem Datensatz mit 14 schwer trennbaren Objektklassen durchgeführt. In Absprache mit dem Max-Rubner-Institut und den Praxispartnern aus der getreideverarbeitenden Industrie wurden diese Klassen zu Obergruppen zusammengefasst, um die Komplexität des Erkennungsproblems zu reduzieren, die bisher schon sehr gute Erkennungsrate von 90 % weiter zu steigern und die Stabilität des Systems zu erhöhen. Als wichtigstes Kriterium für die Unterscheidung der Bestandteile einer Weizenprobe konnte die Farbe ausgemacht werden.

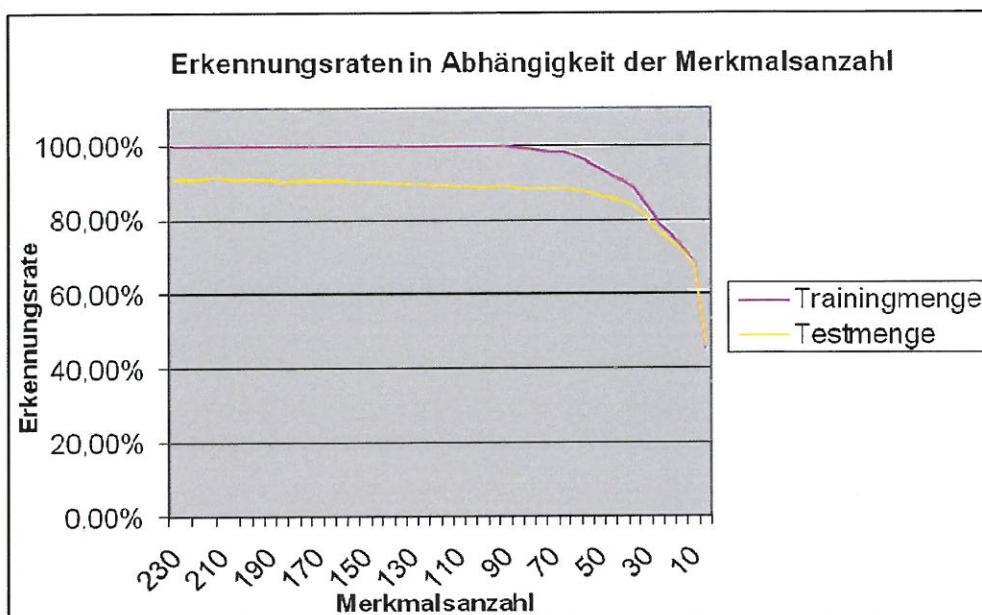


Abbildung 9: Merkmalsselektion mittels Vergleich der Erkennungsraten

Es wurde eine Vielzahl an Untersuchungen zur Evaluierung geeigneter Klassifikationsalgorithmen auf den komplexen Merkmalsvektoren des Getreidedatensatzes durchgeführt, mit dem Ziel den am besten geeigneten Klassifikator mit problemspezifisch angepasster Parametereinstellung zu finden. Dazu wurden Klassifikatoren auf dem neuesten softwaretechnologischen Stand, wie beispielsweise lernende Vektorquantisierung und **Support-Vektor-Maschinen (SVM)**, bezüglich ihrer Eignung für diese komplexe Erkennungsaufgabe untersucht. Dabei überzeugte die SVM als leistungsstärkstes Verfahren (Klassifikatorenvergleich siehe [And 2008], [And 2010a], [And 2010b]). (**Meilenstein 04* - Auswahl Klassifikatoren** ✓)

Die **Klassifikation** im umgesetzten Erkennungssystem erfolgt mit Hilfe des Verfahrens der SVM. Die Entscheidungsfunktion der SVM für den Datenvektor x ist wie folgt definiert [20]:

$$f(x) = \text{sgn}\left(\sum_{i=1}^m \alpha_i y_i k(x, x_i) + b\right)$$

$$\text{mit } k(x, x') = e^{-\gamma \|x-x'\|^2}$$

Die Parameter α_i und α_i und die Support-Vektoren x_i sind mittels der Lerndaten zu bestimmen.




Abbildung 10: Erreichte Erkennungsrate für 23 Objektclassen

Ein wesentliches Leistungsmerkmal eines Bilderkennungssystems sind die Erkennungsrate der einzelnen Klassen. Mit dem ersten Versuchsaufbau konnten bereits hervorragende Resultate erzielt werden. Dies konnte in den ersten durchgeführten Labor-Testreihen bestätigt werden (Abbildung 10 und Abbildung 11). **(Meilenstein 05 – Test des Prototypen unter Laborbedingungen ✓)**

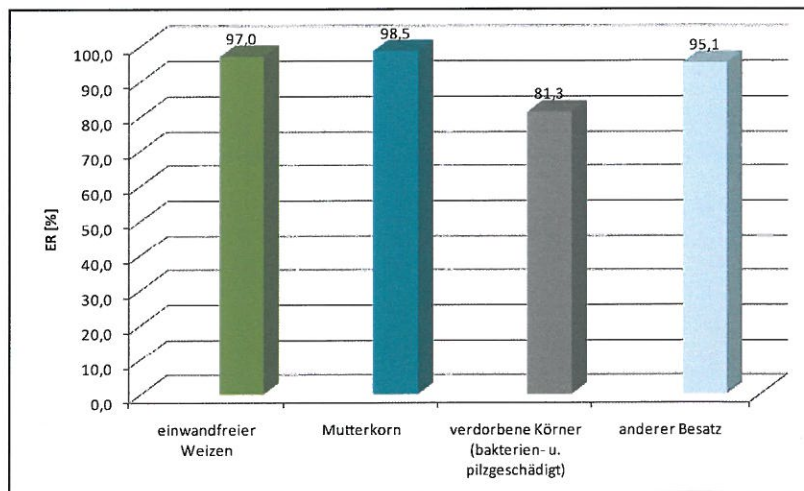


Abbildung 11: Erreichte Erkennungsrate für die zusammengefassten 4 Hauptclassen

Unter Verwendung eines Datensatzes aus 23 Subklassen (verschiedener Getreidearten [wie z. B.: Hafer und Roggen], des Kornbesatzes des Weizens und des Schwarzbesatzes, siehe Abbildung 10) erreichte der angelernte Klassifikator im Testeinsatz eine Gesamterkennungsrate von rund 94% und Einzelerkennungsrate zwischen 69 % und 99 %.

Für die zusammengefassten relevanten Hauptclassen ergeben sich Einzelerkennungsrate die von 81 % bis 99 % reichen (siehe Abbildung 11).

Um die Erkennungssperformance weiter zu steigern, wurden intensive Forschungen auf dem Gebiet der Optimierung der klassifikationsspezifischen Einflussfaktoren durchgeführt [And 2010a], [And 2010b]. **(Meilenstein 06 - Review/Optimierung Software ✓)**. So wurde unter anderem der Einfluss der gewählten Klassenaufteilung, sowohl unter dem Aspekt der erkenntnisstechnologischen Sicht als auch unter der Beachtung gesetzlicher Besatzanalyse-

standards untersucht (aus [And 2010b]). Die Strukturierung der Objektklassen besitzt erheblichen Einfluss auf die Erkennungsleistung, sodass das Finden einer geeigneten Zusammenfassung von Subklassen zu Oberklassen im Mittelpunkt der Untersuchungen stand.

Dafür wurden Klassen mit rein visuell sehr ähnlichen optischen Eigenschaften zusammengefasst (Schema siehe Abbildung 12, Klassen C, D und E), um eine Einschätzung des Potenzials des Verfahrens, eine Einschätzung der Komplexität des Erkennungsproblems und eine Optimierung der Klassifikationsgüte zu ermöglichen. Grundsätzlich wurden zwei Möglichkeiten der Strukturierung der Klassenaufteilungen erarbeitet: Datensatzbeispiele bestimmter schwer trennbarer Subklassen werden vor dem Anlernprozess in die entsprechende Oberklasse zusammengefügt (Schema siehe Abbildung 12, Klasse C2) oder schwer trennbare Subklassen werden mit ihren jeweiligen Datensatzbeispielen für sich getrennt gelernt, bei der Zuordnung der

Erkennungsergebnisse werden jedoch alle zu einer Oberklasse gehörenden klassifizierten Klassenlabels allein in Form ihrer zugehörigen Obergruppe ausgegeben (Schema siehe Abbildung 12, Klasse C1). Die schematische Darstellung der Möglichkeiten der Klassenstrukturierung in Abbildung 12 macht deutlich, dass eine Zusammenfassung der Trainingsinstanzen der schwer trennbaren Klassen C, D und E vor dem eigentlichen Klassifikatortraining zur Oberklasse C2 zu einer suboptimalen Lösung führt, d. h. die Erkennungsrate verbessert sich zwar deutlich gegenüber der Differenzierung dieser drei Einzelklassen, es können jedoch keine optimalen Klassengrenzen (Trennebenen) definiert werden. Hier im Beispiel können durch diese Art der Zusammenfassung sogar neue Überlappungen zur vorher gut differenzierbaren Klasse B auftreten. Die letzte Variante des Trainings mit einzelnen Subklassen und der Erkennung der Zugehörigkeit zu den Klassen A, B und der synthetisch zusammengefassten Klasse C1 gelingt ohne Trennungsschwierigkeiten.

Bei dieser optimalen Lösung wird eine saubere Abgrenzung im Merkmalsraum durch die Existenz exakt definierter Trennebenen möglich, wengleich diese mit einer deutlichen höheren Zahl an benötigten Supportvektoren verbunden ist. Die oben beschriebenen Methoden wurden zur Optimierung der Erkennungsperformance unter anderem auf die einzelnen Klassen des Weizens angewendet, welche z. T. sehr ähnliche optische Eigenschaften aufweisen. Besonders problematisch ist die Trennung zwischen den einzelnen pilzgeschädigten Klassen Fusariumgeschädigter Weizen, rötlich und weißlich verfärbter Weizen, welche alle pilzschadenbedingte Verfärbungen aufweisen. Eine Zusammenfassung dieser Subklassen in die Klasse verdorbener (pilzgeschädigter) Weizen würde auch im Hinblick auf die gesetzlichen Besatzanalysestandards als sinnvoll erscheinen. Diese Überlegungen wurden umgesetzt und erkenntungstechnologisch untersucht (in [And 2010b] beschrieben, siehe Abbildung 13).

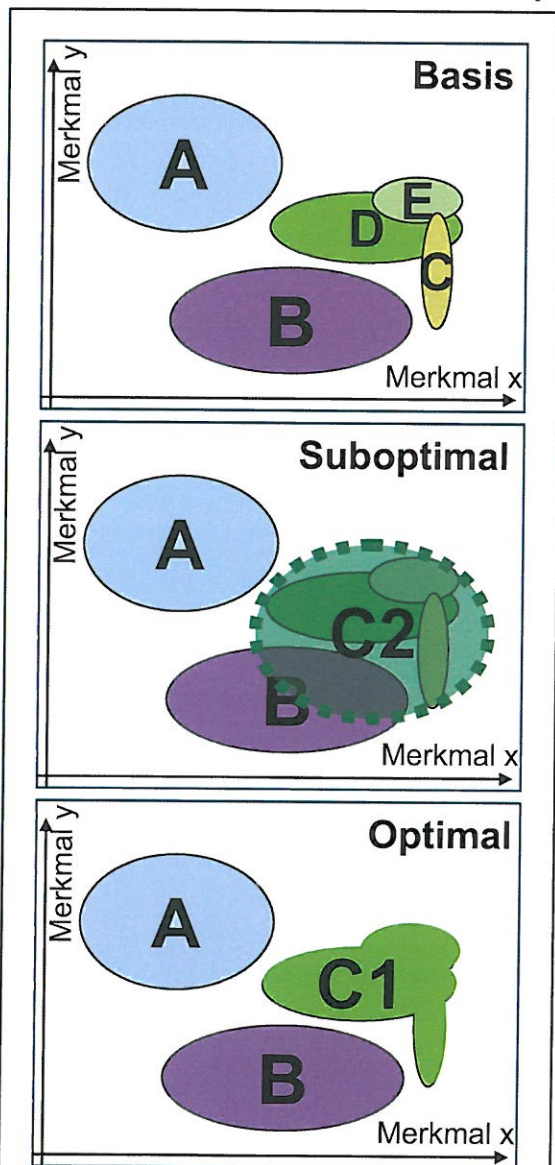


Abbildung 12: Optimale Klassenstrukturierung [And 2010b]

lich verfärbter Weizen, welche alle pilzschadenbedingte Verfärbungen aufweisen. Eine Zusammenfassung dieser Subklassen in die Klasse verdorbener (pilzgeschädigter) Weizen würde auch im Hinblick auf die gesetzlichen Besatzanalysestandards als sinnvoll erscheinen. Diese Überlegungen wurden umgesetzt und erkenntungstechnologisch untersucht (in [And 2010b] beschrieben, siehe Abbildung 13).

einzelne Korn- u. Schwarzbesatzgruppen als Objektklassen													
Supportvektoren 8279													
rbf-Kern, Gamma 0.005, Nu 0.005	U3_a_Kornbesatz_Objektraumstrukturierung	klassifiziert	Auswuchs Weizen	Bruchkorn Weizen	Fraßgeschäd. Weizen	Fraßgeschäd. Weizen	Fusariumgeschäd. Weizen	Keimverfärb. Weizen	Schmachtkorn Weizen	einwandfr. Weizen	rote Körner Weizen	weißliche Körner Weizen	Gesamt-ER [%]
	Auswuchs	367	12	44	0	0	0	10	0	0	0	0	84,78
	Bruchkorn	0	1121	10	2	0	0	0	0	34	0	0	96,06
	Fraßgeschädigter Weizen	40	15	1074	0	0	0	31	0	7	0	0	92,03
	Fusariumgeschädigter Weizen	0	9	0	1	713	0	0	0	2	50	247	89,18
	Keimverfärbungen	0	3	0	3	0	831	0	0	0	40	19	92,75
	Schmachtkorn	6	1	24	0	0	0	678	0	0	0	0	95,63
	einwandfr. Weizen	0	22	2	0	0	0	0	0	1146	0	0	97,95
	rote Körner	0	2	0	0	0	0	35	0	0	0	29	90,21
	weißliche Körner	0	1	1	228	10	0	0	0	0	14	808	88,50
einwandfreier Weizen, Auswuchs, Fraßgeschädigter Weizen, Bruchkorn, Schmachtkorn, Keimverfärbungen, verdorbene Weizenkörner als Objektklassen													
Supportvektoren 5772													
rbf-Kern, Gamma 0.005, Nu 0.005	U3_b_Kornbesatz_Objektraumstrukturierung	klassifiziert	Auswuchs Weizen	Bruchkorn Weizen	Fraßgeschäd. Weizen	Keimverfärb. Weizen	Schmachtkorn Weizen	einwandfr. Weizen	verdorbene Körner Weizen	Einzel-ER [%]	Gesamt-ER [%]		
	Auswuchs	368	11	43	0	10	0	0	1	84,99			
	Bruchkorn	0	1121	9	0	34	0	0	3	96,06			
	Fraßgeschädigter Weizen	40	14	1074	0	31	0	7	1	92,03			
	Keimverfärbungen	0	3	0	819	0	0	0	74	91,41			
	Schmachtkorn	6	1	24	0	678	0	0	0	95,63			
	einwandfr. Weizen	0	22	2	0	0	0	1146	0	97,95			
	verdorbene Körner	0	8	0	59	0	0	0	3119	97,90		95,38	
einwandfreier Weizen, Kornbesatz, verdorbene Weizenkörner als Objektklassen													
Supportvektoren 2927													
rbf-Kern, Gamma 0.005, Nu 0.005	U3_c_Kornbesatz_Objektraumstrukturierung	klassifiziert	Kornbesatz	einwandfr. Weizen	verdorbene Körner Weizen	Einzel-ER [%]	Gesamt-ER [%]						
	Kornbesatz	4247	39	86	97,14								
	einwandfr. Weizen	32	1138	0	97,28								
	verdorbene Körner	98	0	3088	96,92								97,08

Abbildung 13: Klassenstrukturierung am Beispiel der Korn- u. Schwarzbesatzklassen des Weizens [And 2010b]

In der ersten Stufe wurden die Subklassen als einzelne Klassen trainiert. In der zweiten Stufe wurden die Klassen einwandfreier Weizen, Auswuchs-Weizen, fraßgeschädigter Weizen, Bruchkorn-Weizen, Schmachtkorn-Weizen, keimverfärbter Weizen unverändert beibehalten. Es wurden jedoch alle Pilzschaden-bedingt veränderten Weizenkörner (Fusariumgeschädigter Weizen, weißliche und rote Weizenkörner) in der Klasse verdorbene Weizenkörner zusammengefasst trainiert.

Die Gesamterkennungsrate dieser Klassenauswahl liegt bei Verwendung aller Subklassen als Einzelklassen bei 88,5 %. Die pilzgeschädigten Klassen erreichen erwartungsgemäß niedrige Erkennungsraten (Fusariumgeschädigter Weizen 69,2 %, weißliche Weizenkörner 76,1 % und rötliche Körner 90,2 %).

Die Gesamterkennungsrate in der zweiten Stufe bei Verwendung der Subklassen einwandfreier Weizen, Auswuchs-Weizen, Fraßgeschädigter Weizen, Bruchkorn-Weizen, Schmachtkorn-Weizen, keimverfärbter Weizen und der zusammengefassten Oberklasse verdorbene Weizenkörner (pilzschadenbedingt) erreicht 95,4 %. Die Gesamterkennungsrate steigert sich bei Zusammenfassung der pilzgeschädigten Körner zur Klasse verdorbene Körner im Vergleich zur ersten Stufe um rund 7,1 % absolut. Die Einzelerkennungsrate der Klasse verdorbene Körner liegt mit 97,90 % weit über den Einzelerkennungsraten ihrer einzelnen Subklassen im Bereich von 69,2 % bis zu maximal 90,2 %.

Im Ergebnis konnte festgestellt werden, dass eine Zusammenfassung einzelner sehr schwer trennbarer, phänotypisch ähnlicher Subklassen in zweckmäßige Obergruppen sinnvoll ist und zu einer deutlichen Erhöhung der Erkennungsraten führt.


Die gewonnenen Erkenntnisse fließen in die Überarbeitungen des Demonstrators und der Erkennungsroutine ein.

Prototypenerstellung mit optimierter Hard- und Software

Das automatisierte Besatzanalyseverfahren wurde in einen funktionsfähigen Prototyp umgesetzt, welcher unter Laborbedingungen getestet und für den Praxiseinsatz optimiert wurde. Der Prototyp wurde mehrfach Mühlenanwendern, Partner-Verbänden und Experten des Max-Rubner-Instituts vorgeführt und überzeugte dabei die Praxisexperten der Getreidebranche einerseits durch die effiziente objektivierte Messbarkeit der Getreidequalität und andererseits auch durch seine hohe Wiederholgenauigkeit.

Der Prototyp konnte ebenso in Praxistests in den Partner-Mühlen vor Ort überzeugen.

Das in den Prototypen überführte Verfahren wird von den Fachleuten als innovativer neuer Stand der Technik in der Besatzanalyse von Getreide angesehen mit dem positiven Ergebnis einer deutlichen Erhöhung der Lebensmittelsicherheit.

Das entwickelte automatisierte Besatzanalyseverfahren stellt nach kurzer Analysezeit umfangreiche Ergebnisse zur Verfügung. Mit einer Analysezeit von rund 6 Minuten bei einer Probengröße von ca. 320 g werden die gestellten Anforderungen erfüllt (**Meilenstein 07-Bewertung der automatisierten Besatzanalyse** ). Im Beispiel wurde eine Weizenprobe in die sieben Klassen Kornbesatz, Bruchkorn, einwandfreier Weizen, Hafer, Mutterkorn, Raps, Spelzen und Steine klassifiziert. Dabei werden folgende Information ausgegeben:

- exakte Anzahl der Objekte in den Klassen,
- Probenzusammensetzung (Säulendiagramm),
- Bilder aller Objekte im Speicher,
- Prognose des Gewichts der Fraktion einwandfreien Weizen,
- Numerische Statistik der analysierten Probe,
- Grafische Statistik der analysierten Probe.

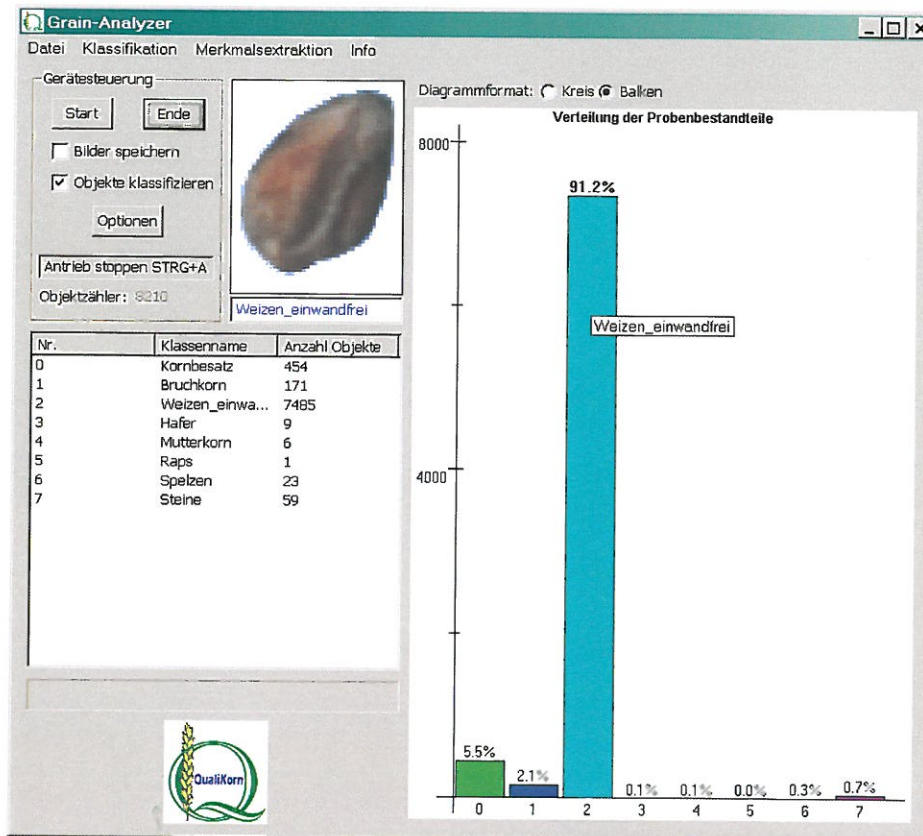


Abbildung 14: Bildschirmdarstellung des Analyseergebnisses

Diese Informationen stehen dem Benutzer in numerischer und graphischer Form zur Verfügung, wie in Abbildung 14 dargestellt. Die Programmoberfläche wurde so gestaltet, dass eine Anpassung der Klassifikatormodelle an andere Getreidesorten einfach möglich ist. Dazu wurden entsprechende Funktionalitäten und Dialogmenüs für Datenerhebung, Training und Test im Rahmen der Erstellung eines neuen Klassifikatormodells eingefügt.

Die Analyse-Daten können so in die spezifischen Formulare der jeweiligen Betriebe, entsprechend den gesetzlich geforderten Angaben zur Dokumentation, übertragen, ausgedruckt und gesichert werden.

Die nachfolgende Erläuterung der Bedienung des Programmes „Grain-Analyzer“ in Verbindung mit dem Versuchsaufbau „Grainspector“ ist dem Anhang der Dissertation [Gar 2011] entnommen (vgl. Anhang F Programmbedienung Grain-Analyzer). Die Screenshots sind mit der deutschsprachigen Variante des Programms entstanden. Es existiert jedoch ebenfalls eine englischsprachige Programmversion.

Programmbedienung Grain-Analyzer (aus [Gar 2011])

1. Durchführung der Analyse einer Weizenprobe

Nach Einfüllen des Probenmaterials von 500 g, welches einer Siebung zum Abscheiden von kleinen Staub- und Schmutzpartikeln (< 1mm) und großen Bestandteilen (> 8mm) unterzogen wurde (Schutz vor Staus im Fördersystem, Schutz vor übermäßiger Staubentwicklung im Gerät), wird die Analyse über den Button „Start“ gestartet. Hat sich der Behälter vollständig entleert, kann mit „Ende“ die Bildaufnahme beendet werden. Die Ergebnisse werden nun ausgewertet und die Zusammensetzung der Probe in Stückprozent im Diagramm (umschaltbar zwischen Balken- und Kreisdiagramm) dargestellt. Weiterhin werden der mittlere Flächeninhalt und der mittlere Objektdurchmesser der längsten Ausdehnung angegeben.

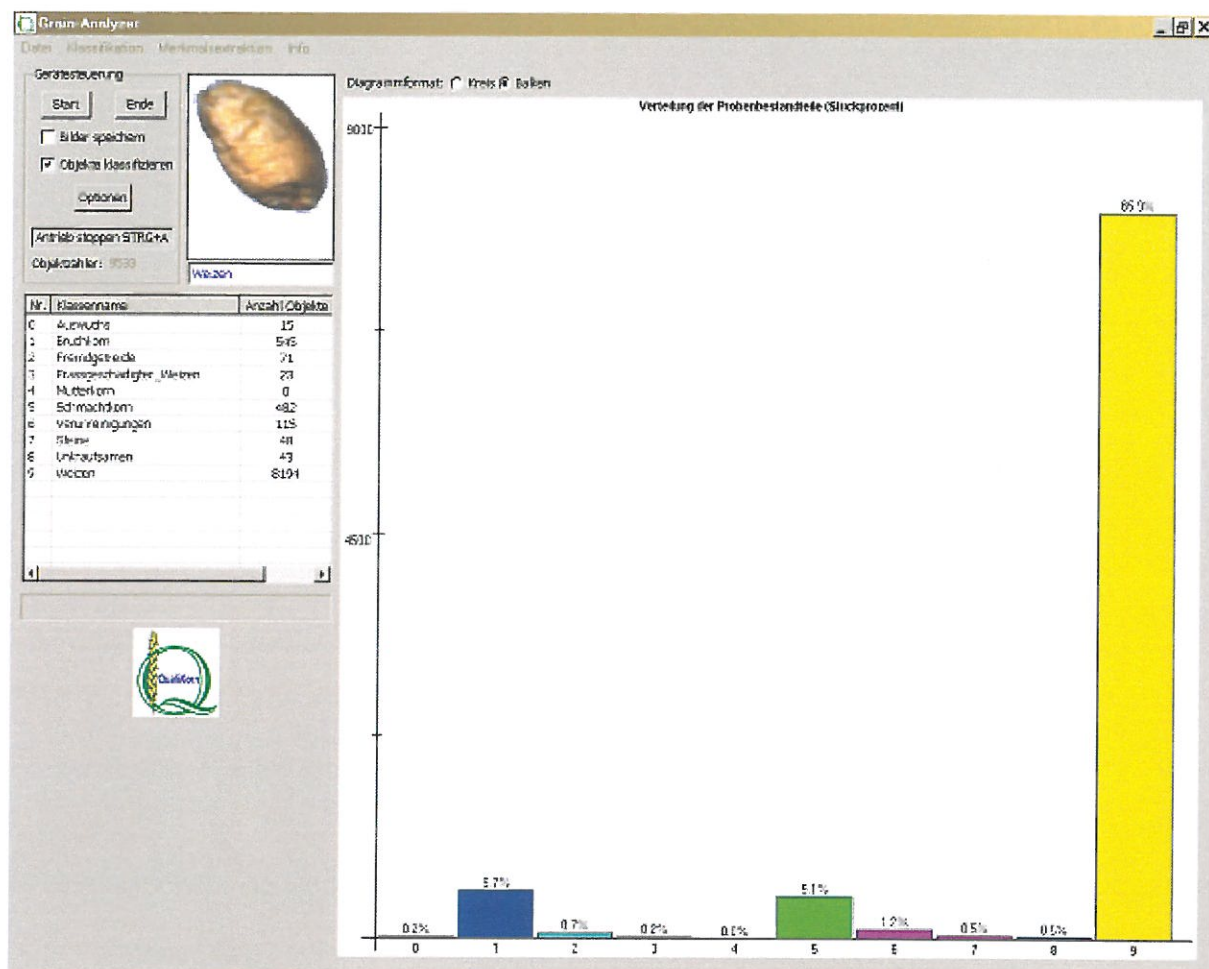


Abbildung 15: Darstellung der Auswertergebnisse im Balkendiagramm [Gar 2011]

Wird der Mauszeiger über das Diagramm bewegt, so erscheint eine Zusatzinformation mit dem Namen der jeweiligen Besatzklasse (Abbildung 16). Dies ermöglicht auch eine übersichtliche Anzeige von Diagrammen mit einer hohen Anzahl an unterschiedenen Klassen. Über den Menüpunkt „Datei -> Ergebnisse speichern“ lassen sich die Ergebnisse im CSV-Format speichern. Dies ermöglicht eine leichte Datenübernahme in Excel.

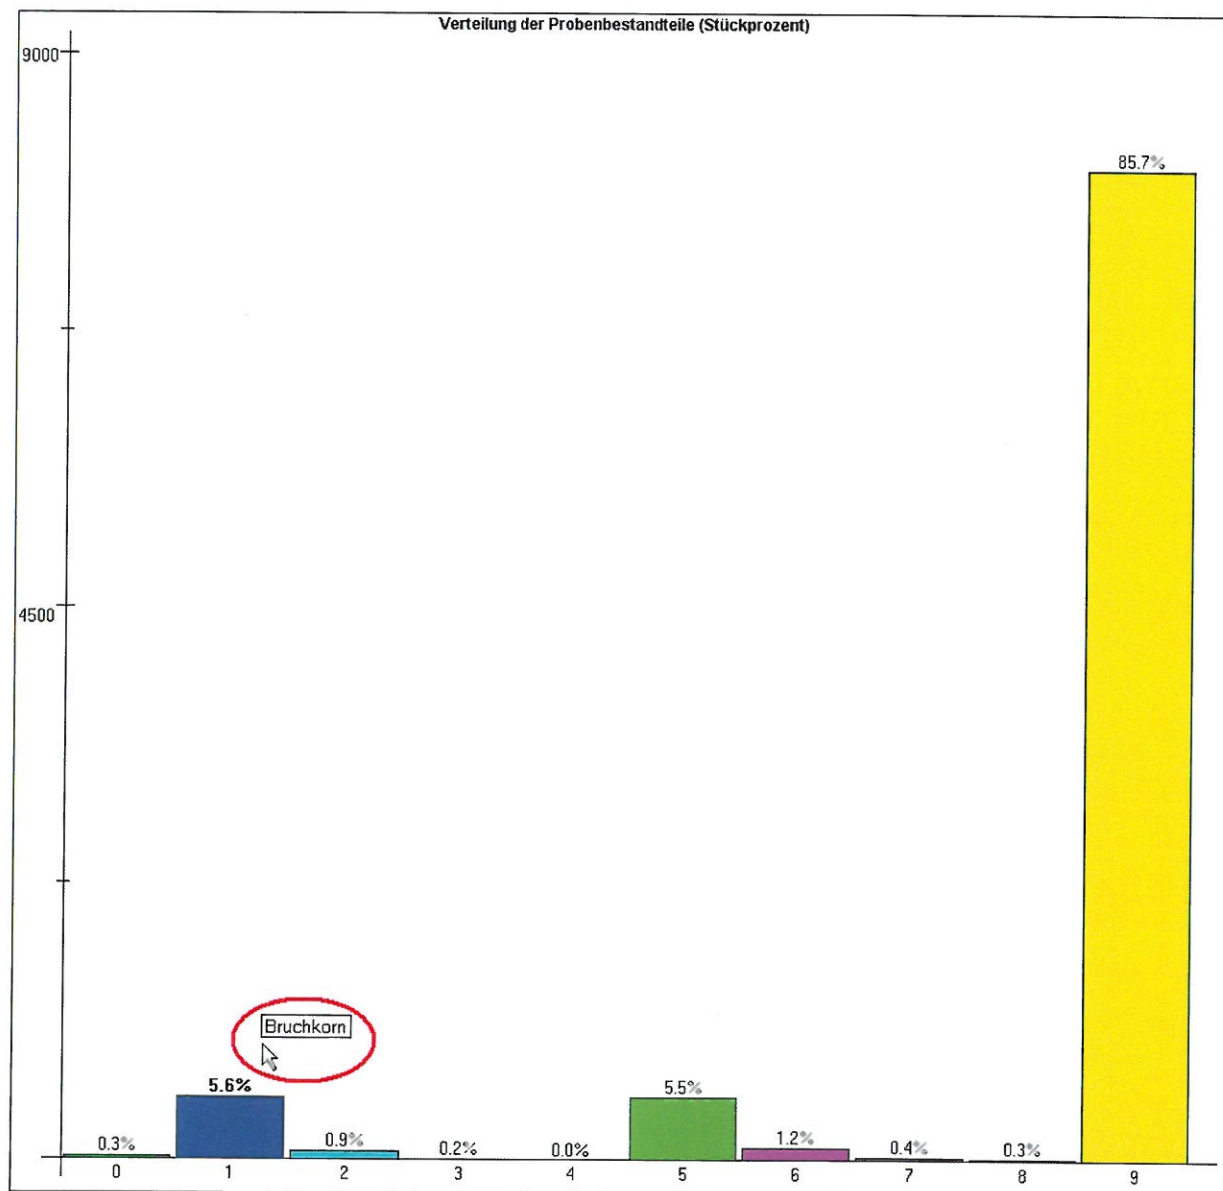


Abbildung 16: Anzeige des Namens der Besatzklasse im Diagramm [Gar 2011]

Wird in der Ergebnistabelle eine Zeile angeklickt, so öffnet sich ein Fenster mit allen Bildern, die in die betreffende Klasse einsortiert wurden. Zusätzlich kann ein Anwender mit Expertenwissen die Zuordnung einzelner Bilder ändern, indem er diese markiert und eine neue Klassenbezeichnung wählt (Abbildung 17).




Abbildung 17: Manipulation der Klassenzuordnung [Gar 2011]

2. Aufnahme eines neuen Datensatzes für das Training

Da die Software lernfähig gestaltet wurde, ist es denkbar, Datensätze mit anderen Getreidesorten aufzunehmen und den Klassifikator neu zu trainieren. Hierzu ist es nötig, dass für jede zu unterscheidende Klasse eine ausreichende Zahl (2000 oder mehr) vorklassifizierter Objekte bereit gehalten wird.

Die Bilder werden jeweils einzeln für jede Klasse aufgenommen. Hierzu wird in der Programmoberfläche ein Häkchen bei „Bilder speichern“ gesetzt (Abbildung 18) und die Bildaufnahme gestartet. Mit dem Beenden der Bildaufnahme werden alle Bilder in den unter „Optionen -> Pfad für Ablage der aufgenommenen Objektbilder“ (Abbildung 20) angegebenen Ordner gespeichert. Die Speicherung erfolgt verlustfrei im Windows-Bitmap-Format.

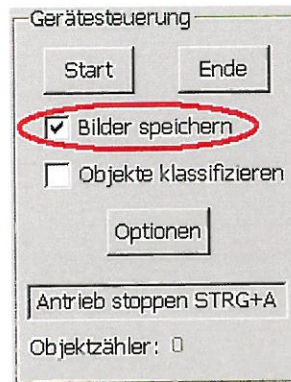


Abbildung 18: Bilder speichern [Gar 2011]

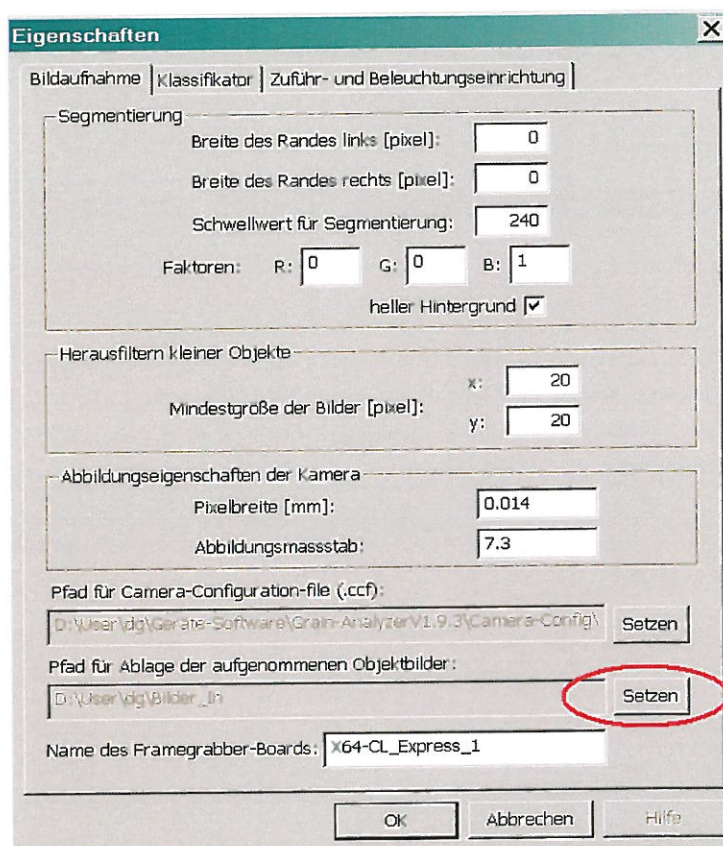


Abbildung 19: Auswahl des Pfades zur Ablage der Bilder [Gar 2011]

Sind nun alle Bilder aufgenommen, ist der Datensatz in einen Ordner abzulegen. Die Trainingsbilder für die einzelnen Klassen werden jeweils in Unterordner abgelegt (Abbildung 20). Hierbei wird jeweils der Name des Unterordners als spätere Klassenbezeichnung übernommen.

Vor dem Training ist darauf zu achten, dass der gesamte Bilddatensatz von Abbildungsfehlern und Objekten, bei denen der zu erkennende Defekt nicht klar sichtbar ist, bereinigt wird. Dies sollte von einem erfahrenen Mitarbeiter mit Spezialwissen aus dem Anwendungsbereich erfolgen.

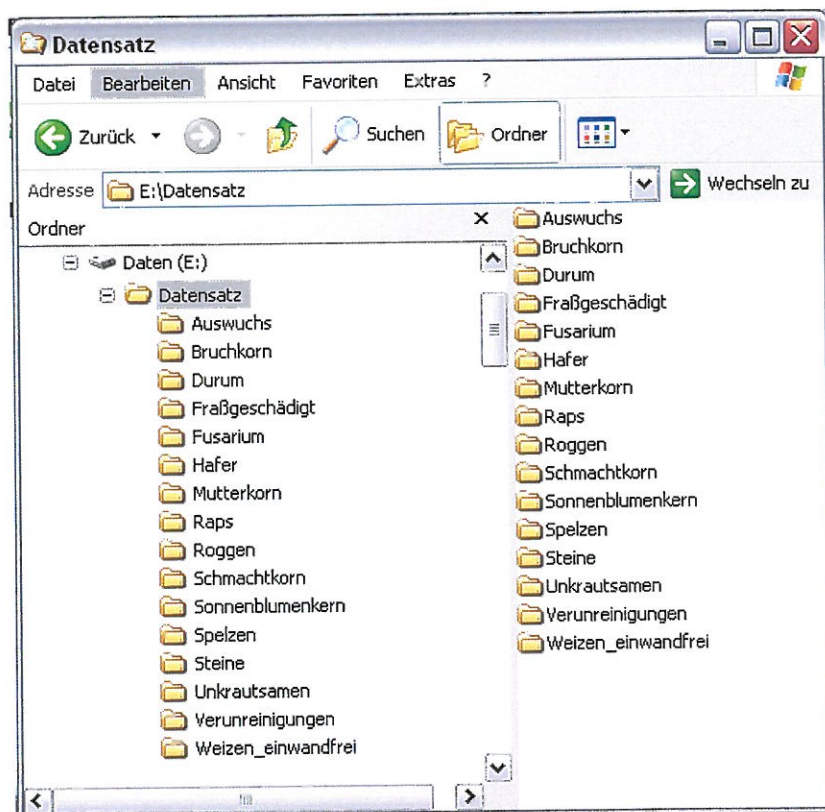


Abbildung 20: Ablage der Bilddaten für das Training [Gar 2011]

3. Durchführung von Klassifikatortraining und Test

Über den Menüpunkt „Klassifikation -> Klassifikator trainieren“ wird das unten stehende Dialogfeld geöffnet. Hier ist der Pfad mit den Trainingsbildern anzugeben. Im ersten Schritt sollte nun die Eignung der gewählten SVM-Parameter getestet werden. Dies erfolgt durch eine einfache Hold-out-Schätzung, wobei der Anteil der Trainingsmenge am Gesamtdatensatz anzugeben ist, der Rest wird zum Test verwendet. Nach dem Anklicken von „Starte Test“ ist ein Pfad für die Datei mit den Testergebnissen auszuwählen. Liegt ein gültiger Pfad vor, so wird der Datensatz zufällig nach den gewählten Angaben in Trainings- und Testmenge aufgeteilt und das Training mit anschließendem Test durchgeführt. Aus Erfahrung empfiehlt sich die Verwendung der in Abbildung 21 dargestellten Parameter mit dem RBF-Kernel. Sollten diese keine zufrieden stellenden Ergebnisse liefern, so ist eine Optimierung der Parameter „Nu“ und „Kernel Parameter“ (Gamma bei RBF-Kernel, Grad des Polynoms bei polynomialer Kernel-Funktion) in sinnvollen Grenzen nach dem in der vorliegenden Arbeit vorgestellten Schema nötig.

Sind die optimalen Parameter gefunden, so kann mittels „Erstelle Modell“ der neue Klassifikator trainiert werden. In dem sich nun öffnenden Dateidialog sind Dateiname und Pfad für das Klassifikatormodell und für die Textdatei mit den Klassenbezeichnungen anzugeben. Weiterhin ist es möglich, eine bereits trainierte SVM mit gleicher Klassenstruktur durch neue Daten für die jeweilige Klasse zu erweitern, um z. B. die Sub-Klassen des Weizens mit Bildern anderer Weizensorten zu erweitern. Die Aufnahme neuer Klassen in ein bereits trainiertes Modell ist nicht möglich.

SVM-Training

Klassifikatorparameter

Pfad des Ordners mit den Trainingsbildern
E:\Datensatz

Kernel-Funktion: RBF

Kernel-Parameter: 0.03

Komplexitätsparameter Nu: 0.01

Parameter Epsilon: 0.01

Minimaler Flächeninhalt: 50

Initiale SVM

Modell-Datei der initialen SVM
Pfad

Klassifikatorstest / Parameterstest

Anteil Trainingsmenge: 0.66

Hinweis: Je nach Datensatzgröße und Wahl der Parameter kann das Training mehrere Minuten dauern. Das Ende des Trainingsvorgangs wird durch eine MessageBox angezeigt.

Abbildung 21: Dialog SVM-Training [Gar 2011]

4. Einbinden des trainierten Klassifikators

Über den Button „Optionen“ öffnet sich der Dialog zur Eingabe von Programmparametern. Unter dem Reiter „Klassifikator“ sind die neu erzeugten Dateien auszuwählen. (Abbildung 22) Bei den nächsten Analysen wird nun das hier angegebene Klassifikatormodell geladen.

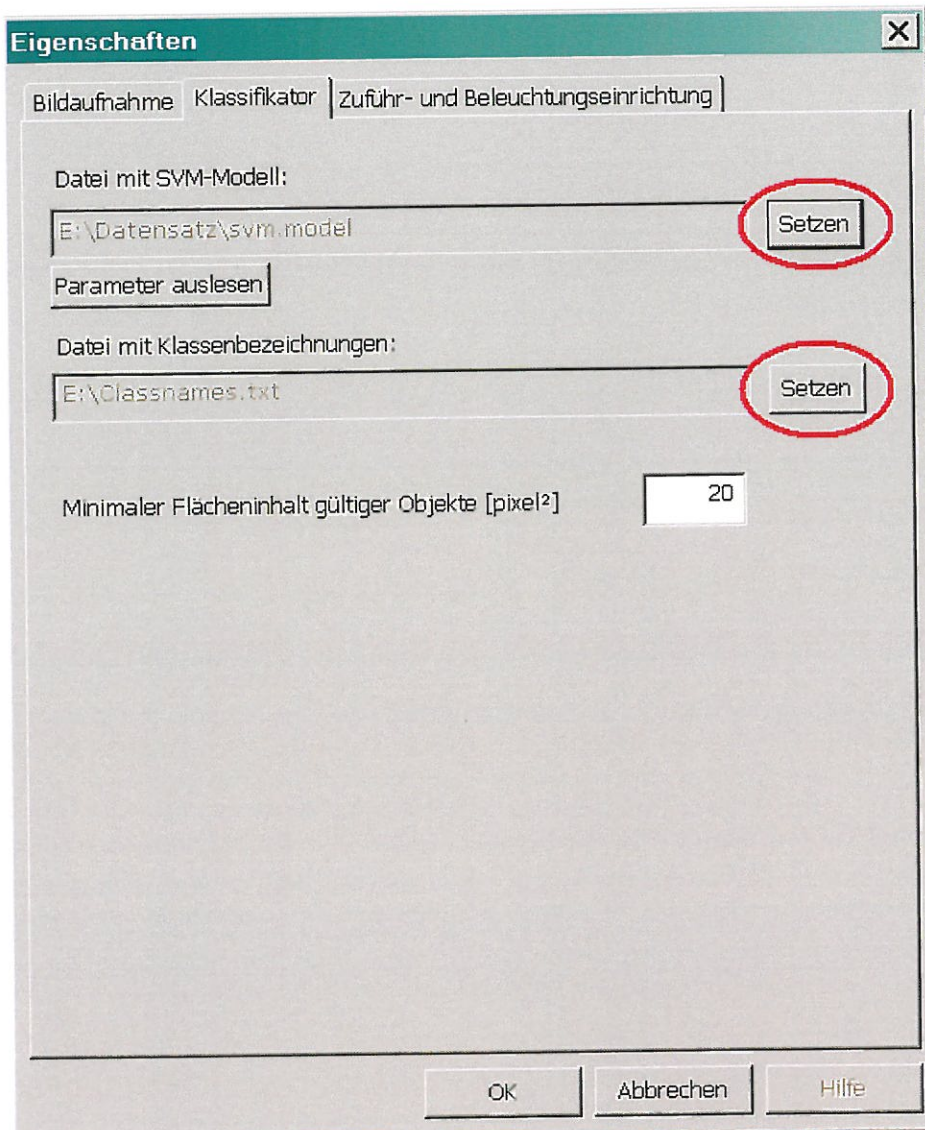


Abbildung 22: Einbinden des neuen Klassifikators [Gar 2011]

5. Abfrage der Klassifikatorparameter des hinterlegten SVM-Modells

Über den Punkt „Parameter auslesen“ lassen sich die wichtigsten Parameter (Art der Kernel-funktion, Kernel-Parameter und Komplexitätsparameter ν) des aktuell verwendeten Klassifikatormodells auslesen.

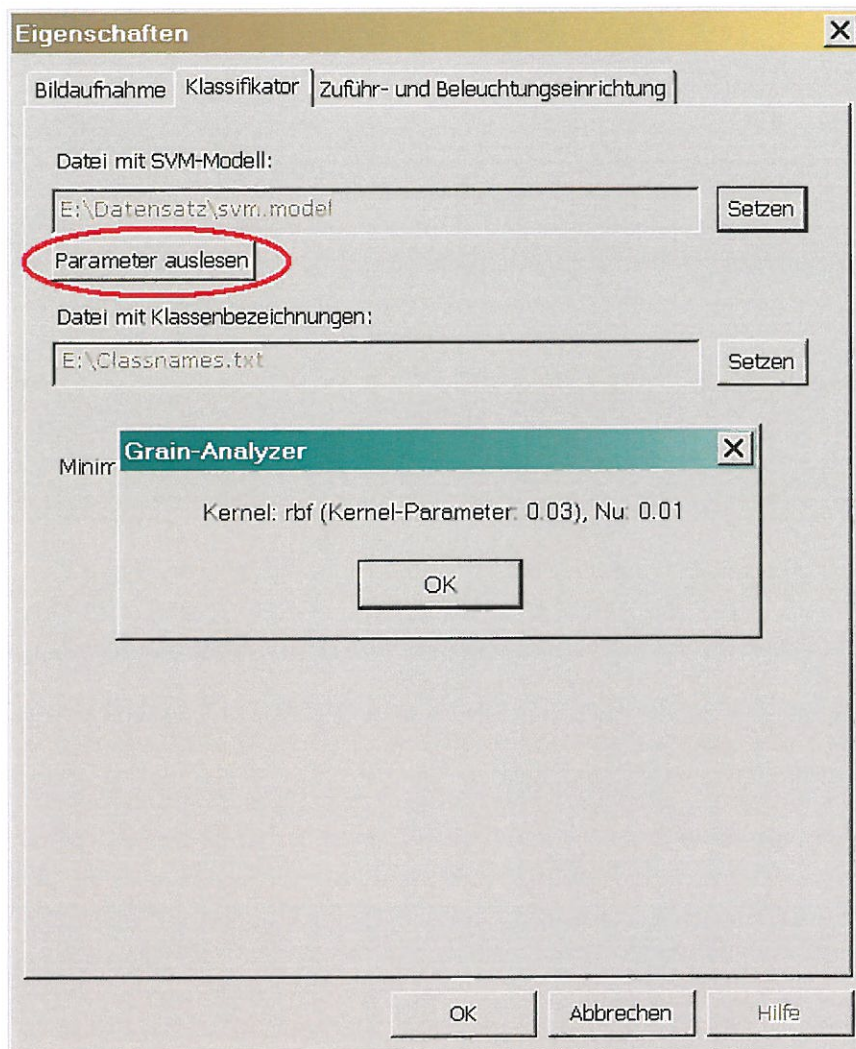


Abbildung 23: Klassifikatorparameter abfragen [Gar 2011]

In allen Teilbereichen wurden hervorragende Lösungen erreicht und zu einem Gesamtkomplex zusammengeführt. Sehr intensiv wurde dafür mit allen beteiligten Projektpartnern zusammengearbeitet, um diese Ergebnisse interdisziplinär erreichen zu können. Aufgrund des, auch durch Vorstellung der Ergebnisse in Presse und Fernsehen geweckten, hohen Interesses an der Überführung und Fertigung, insbesondere durch Partner in Thüringen, wurde auch bereits eine Designstudie für ein Gerät zur Besatzanalyse von design:lab weimar GmbH erstellt. Die Abbildung 24 gibt diesen Entwurf wieder.



Abbildung 24: Designstudie für ein Besatzanalysegerät

Demonstratoren für Prinziplösungen zur Besatzanalyse

Die Zuwendung wurde dem Antrag entsprechend eingesetzt. Die wissenschaftlich-technischen Ergebnisse des Forschungsprojekts sind auch in zwei Funktionsdemonstratoren eingeflossen, die jeweils ein anderes Prinzip der Bewegung des Messgutes während der Bildaufnahme umsetzen. Die Bildaufnahme funktioniert bei beiden Lösungen prinzipiell gleich, jedoch sind Kamera und Beleuchtung an den jeweiligen Versuchsaufbau angepasst. Der erste Funktionsdemonstrator für die Besatzanalyse setzt das Grundprinzip des freien Falls um (Prinzip „Freier Fall“). Beim zweiten Funktionsdemonstrator werden die Proben auf einem Band inspiziert (Prinzip „Auf Band“). Mit beiden Funktionsdemonstratoren wurden umfangreiche Tests zur Bestimmung der Erkennungsraten für die unterschiedlichen Korn- und Besatzfraktionen durchgeführt. Die sehr guten Ergebnisse wurden national und international publiziert. Erste praktische Demonstrationen der automatisierten Besatzanalyse erfolgten im Jahre 2009 anlässlich des Meetings im Max-Rubner-Institut in Detmold sowie bei den Projektpartnern GFE Schmalkalden und Heimatsmühle Aalen. Darüber hinaus wurde im Jahre 2010 das Auf-Band-Gerät in den beiden am Projekt beteiligten Mühlen Landshuter Kunstmühle C. A. Meyer's Nachf. AG in Landshut und Heimatsmühle Maximilian O. Ladenburger in Aalen einem mehrtägigen erfolgreichen Praxistest unterzogen. Ein weiterer, einen längeren Zeitraum umfassender Praxiseinsatz erfolgte bei der Firma GEKRA in Querfurt, einem Silobetrieb.

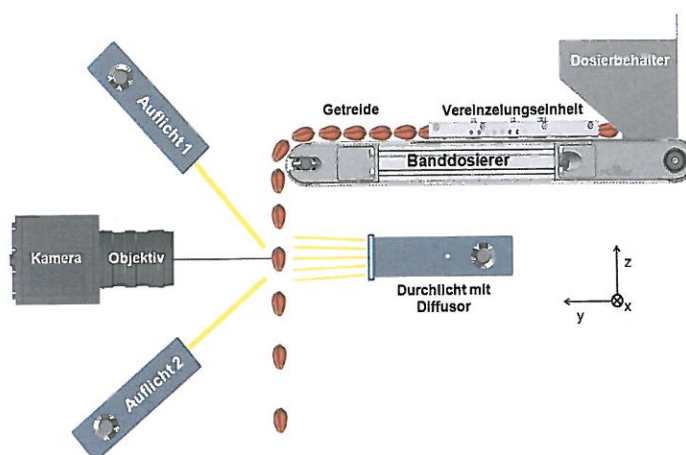


Abbildung 25: Schematische Darstellung des Grundprinzips „Freier Fall“

Beim Grundprinzip des „Freien Falls“ werden die Körner zunächst vereinzelt. Dies geschieht mit einer Einheit aus Dosierbehälter, Bandförderer und Vereinzelungsvorrichtung. Am Ende des Bandes gehen die Objekte in den freien Fall über und werden nach einer gewissen Fallhöhe (ca. 50 mm) mit einer Farbzeilenkamera endlos erfasst. Vorteile des Prinzips „Freier Fall“ sind der hohe Durchsatz, die grundsätzliche Möglichkeit der Beobachtung von zwei Seiten, wofür ein zweites System aus Kamera und Beleuchtung notwendig wäre und die prinzipielle Anschlussfähigkeit von Ausblaseeinheiten zur klassenspezifischen Objekt-sortierung. Nachteilig sind die nicht ganz zu kompensierenden Eigenbewegungen der Körner. Durch Eigenrotation oder durch Bahnveränderungen kann die Bilderfassung bei einzelnen Objekten beeinträchtigt werden.




Abbildung 26: Schematische Darstellung des Grundprinzips „Auf Band“

Beim Grundprinzip des „Auf Band“ werden die Körner zunächst in gleicher Weise vereinzelt. Dies geschieht ebenfalls mit einer Einheit aus Dosierbehälter, Bandförderer und Vereinzelungsvorrichtung. Am Ende des Bandes gehen die Objekte jedoch nicht in den freien Fall über, sondern gelangen auf ein zweites Band, das sich mit höherer Geschwindigkeit als das erste bewegt. Mit der Vereinzelungsvorrichtung erfolgt eine Objektseparation in Querrichtung zum Band und mit der unterschiedlichen Bandgeschwindigkeit eine Objektseparation in Längsrichtung zum Band. Auch hier werden die Objekte mit einer Farbzeilenkamera endlos erfasst. Vorteile des Prinzips „Auf Band“ sind die stabile Lage, die homogene Ausrichtung der Körner und die konstante, frei wählbare Geschwindigkeit der Objekte. Nachteilig sind der etwas geringere Durchsatz und die prinzipielle Beschränkung auf eine Ansicht, sowie mögliche Berührungen und Überlappungen der Objekte im Kamerabild, welche jedoch aufgrund der relativ geringen Auftretshäufigkeit und charakteristischen Erscheinungsform der Objekte im Bild mittels eines neuen Ansatzes in Verbindung mit der SVM beherrscht werden konnte. Hierbei wird dieser Bilderfassungsfehler als eine Klasse in den Klassifikator integriert und stellt damit eine Art „Rückweisungsklasse“ dar. Eine physikalische Objektrennung ist grundsätzlich zwar möglich, jedoch nur mit technisch deutlich anspruchsvolleren Lösungen als beim freien Fall.

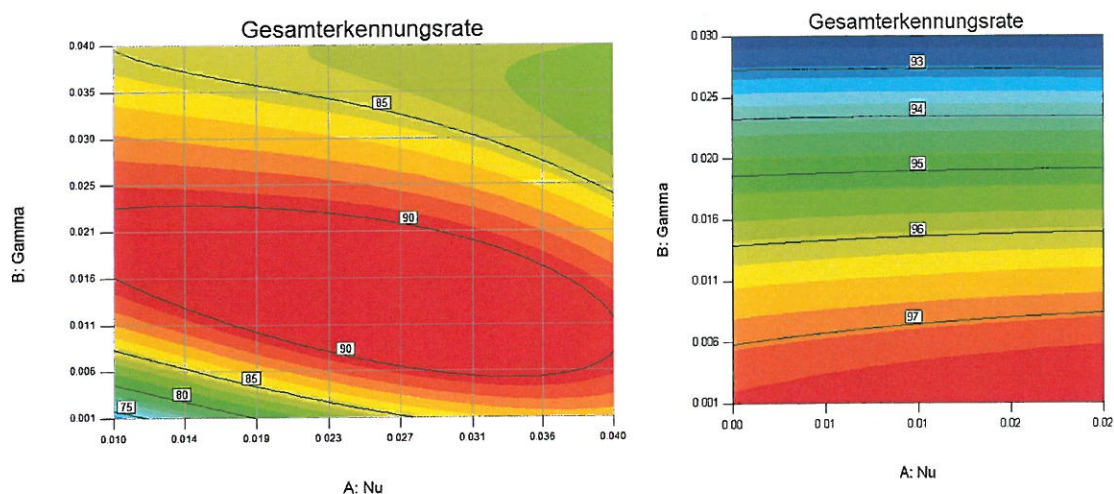


Abbildung 27: Gesamterkennungsrate „Freier Fall“ (links) u. Gesamterkennungsrate „Auf Band“ (rechts) [Gar 2011]

Der Vergleich der Gesamterkennungsraten in Abbildung 27 zeigt bessere und stabilere Werte für die Lösung „Auf Band“. Daher wurde ab Januar 2010 diese Lösung weiter ausgebaut und als Testdemonstrator eingesetzt. Für die potenzielle Umsetzung in ein Erzeugnis wurde die Bezeichnung:

grainspector

als besonders zutreffend angesehen u. in Veröffentlichungen bekannt gegeben [Mun 2010].




Abbildung 28: Demonstrator nach dem Prinzip „Auf Band“ ohne Verkleidung

Die Tests unter Praxisbedingungen mit dem optimierten Auf-Band-Demonstrator (siehe Abbildung 28) zeigten ebenfalls gute Erkennungsraten insbesondere im Hinblick auf erweiterte Testbedingungen in Form von Getreideproben neuer Erntejahre (2009/2010) sowie anderer lokaler Feld-Standorte als im zuvor durchgeführten Training (vgl. Abbildung 29 und Abbildung 30).

Die in den Mühlenpraxisuntersuchungen zugrunde liegende größere Variabilität des Getreides der neuen Ernte spiegelt sich, wie zu erwarten war, auch in einer geringfügigen Verschlechterung der Erkennungsperformance wieder. Mit dem Demonstrator konnten unter Verwendung eines Datensatzes aus 11 Objektklassen im Praxis-Testeinsatz jedoch gute Einzelerkennungsraten zwischen 66 % und 97 % erreicht werden (Abbildung 29). Für die zusammengefassten relevanten Hauptklassen ergaben sich jedoch sehr gute Einzelerkennungsraten von 82 % bis 97 % (siehe Abbildung 30).

Somit konnte gezeigt werden, dass die Ergebnisse des Demonstrators selbst bei großer Variabilität des Probengutes (anbaubedingt, klimatisch-bedingt, getreidesortenbedingt, ..) noch als überdurchschnittlich gut einzuschätzen sind und dass somit durchaus eine Alternative zum bisherigen manuellen Verfahren erarbeitet werden konnte.

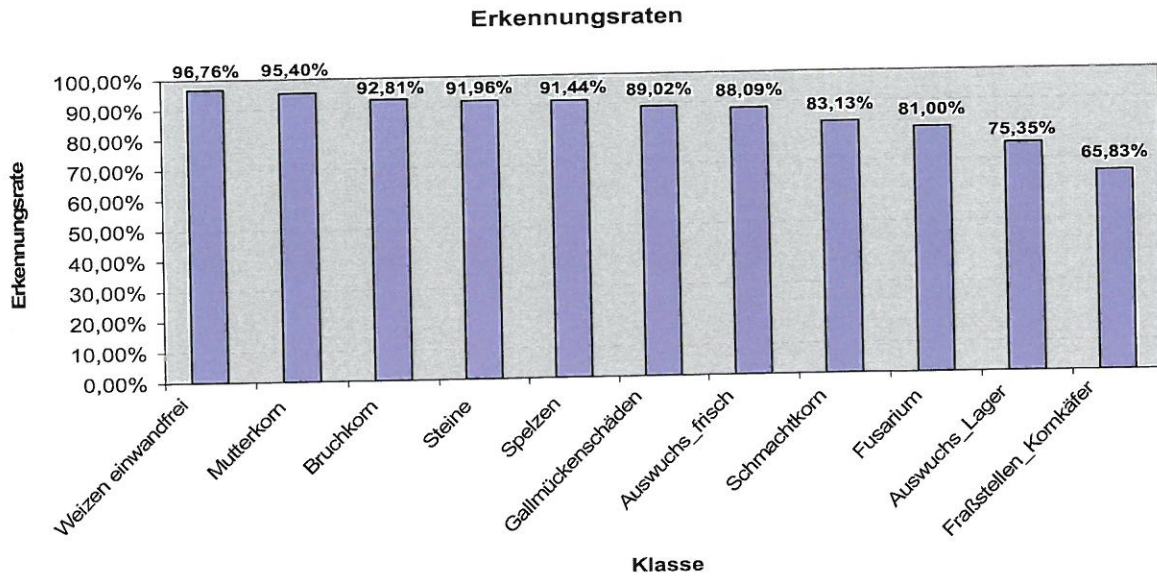


Abbildung 29: Praxistest auf Basis der neuen Ernten 2009/2010

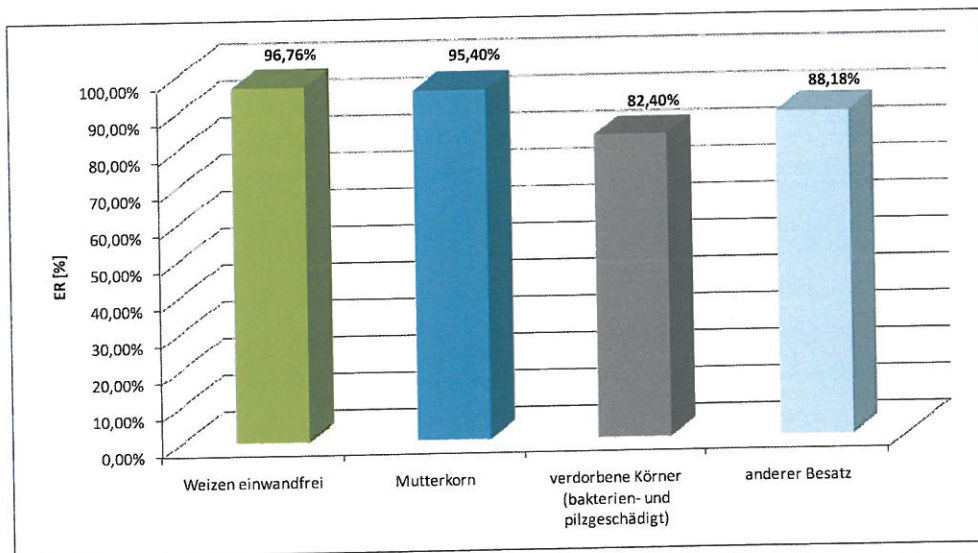


Abbildung 30: Erreichte Erkennungsraten für die zusammengefassten 4 Hauptklassen im Praxistest (Basis: neue Ernten 2009/2010)

Berechnung der Masse von Körnern und Besatzfraktionen

Versuchsreihen mit schnell-schaltenden Ausblasventilen zeigten, dass eine physikalische Trennung aller Objektklassen nur mit hohem technischem Aufwand umsetzbar ist. Dies findet Begründung in den Masse- und Geometrieunterschieden der verschiedenartigen Objektklassen, wie zum Beispiel leichte, relativ großflächige Spelzen, kleine und große Steine mit hohem Masseanteil, kleine, runde Rapssamen mit mittlerer Masse. In Absprache mit den Projektpartnern wurde eine andere Lösung analysiert und umgesetzt. Dabei wird mit Hilfe der Bildinformation jedes Objektes der Probe nach seiner Klassifikation ein Gewicht über eine mittlere Flächendichte jeder Objektklasse durch eine spezielle Softwareroutine ermittelt.




Abbildung 31: Massebestimmung mit Flächendichteverfahren

Tabelle 3: Elektronische Bestimmung der Objektmasse mittels Flächendichte

Messung	1	2	3	4	5	6	7	8	9	10
Masse [g]	49,9286	49,9274	50,0982	50,0678	50,1042	49,6907	50,6352	49,6174	49,7227	50,2238
Spannweite [g]			1,018							
Spannweite [%]			2,03							
Standardabweichung [g]			0,299							
Standardabweichung [%]			0,60							

Die Tabelle 3 gibt eine Messreihe für eine Weizen-Probe von 50 g mit dieser neuartigen Methode wieder. Es wurde eine Standardabweichung von 0,299 g bzw. 0,60 % erreicht. Die Ergebnisse zeigen, dass die Massebestimmung der einzelnen Objektklassen alternativ auch mit dem Flächendichteverfahren hinreichend genau ausgeführt werden kann.

Der gesamte programmtechnische Ablauf des Erkennungsprozesses ist in Abbildung 32 nochmal anschaulich als UML-Aktivitätsdiagramm dargestellt. Die softwaretechnische Umsetzung erfolgte in C++ unter Nutzung der MFC-Bibliothek zur Umsetzung der Benutzeroberfläche. Im Ergebnis entstand eine komplexe Software (**Meilenstein 06 - Review/Optimierung Software**) , deren Module sowohl einzeln als auch in Kombination mit dem Versuchsaufbau „grainspector“ ausgiebig getestet wurden, sowohl im Labor als auch im Praxiseinsatz.

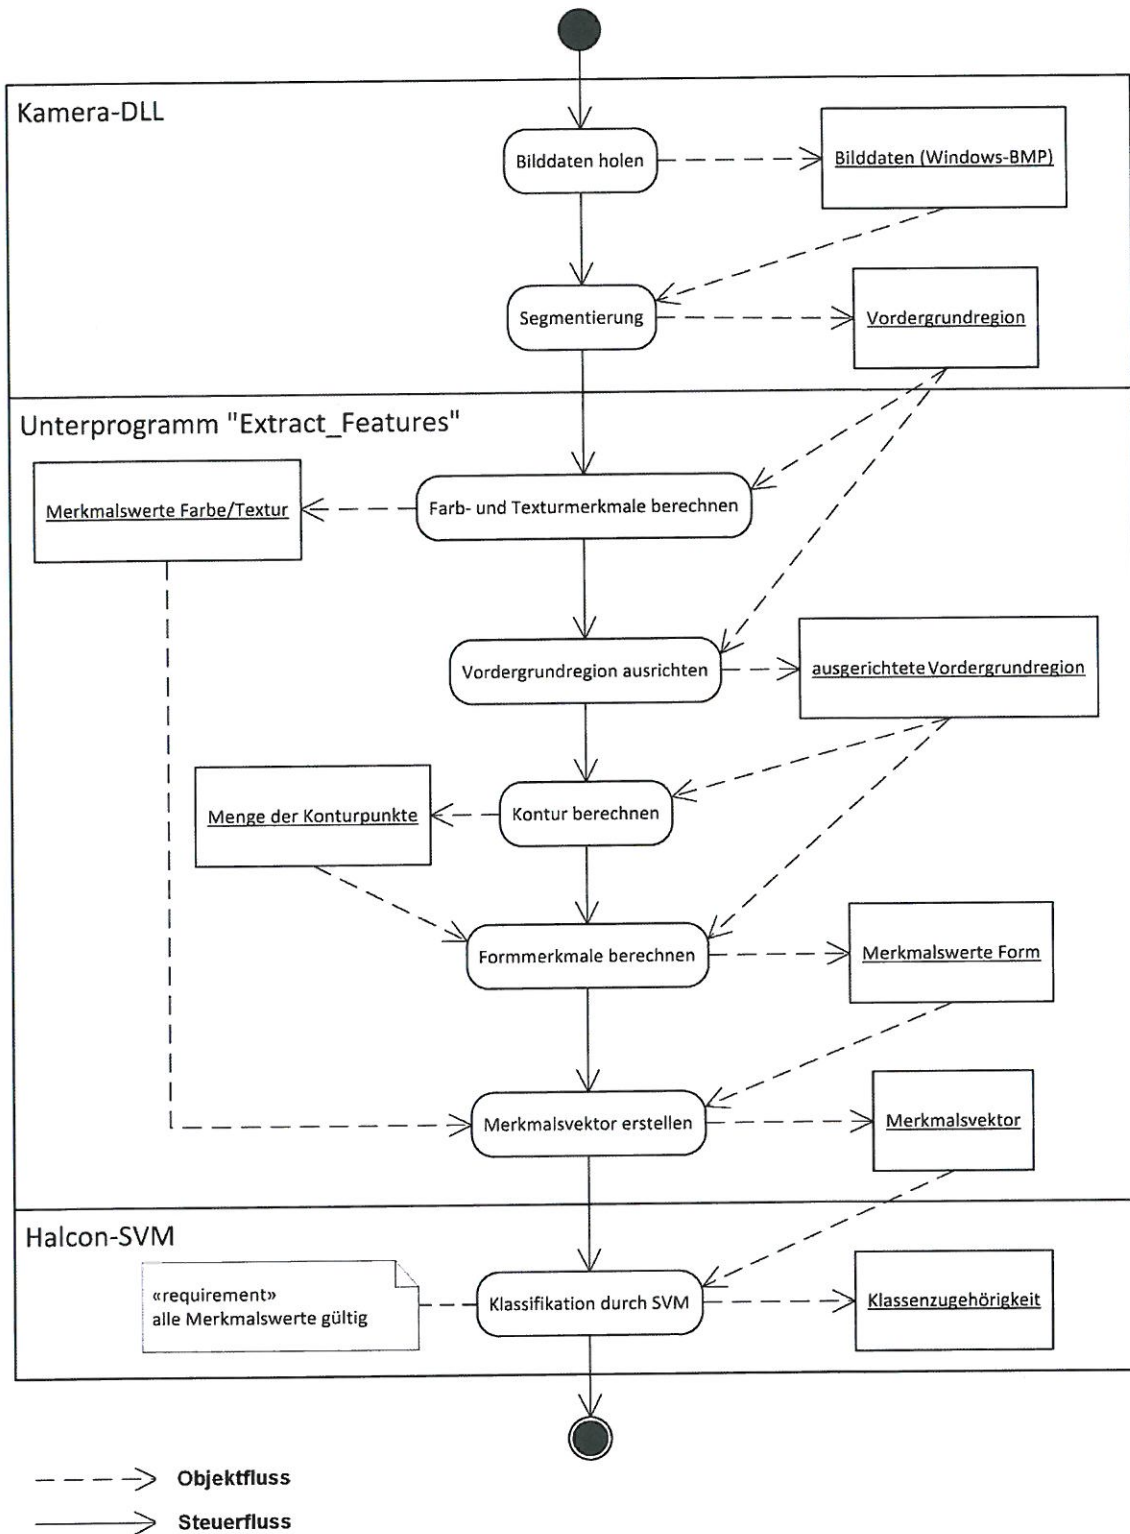


Abbildung 32: Erkennungsprozess als UML-Aktivitätsdiagramm

Neben der Besatzanalyse zur Determinierung der Getreideprobenbestandteile spielte die Ermittlung des Gehaltes an pilzschadenbedingten Giftstoffen eine Rolle im Rahmen des Forschungsprojektes QualiKorn. Die Giftstoffe werden in der Praxis bisher mittels chemischer Schnelltests und chemischer Laboranalysen detektiert. Das Vorhandensein von Mykotoxinen (wie z. B. Deoxynivalenol, Zearalenon) kann derzeit mit chemischen Schnelltests und immunochemischen Methoden (ELISA) mit kurzer Analysezeit aber geringerer Exaktheit oder aber mit hochpräzisen, zeitaufwendigen chromatographischen Methoden in Speziallaboren bestimmt werden. Genau hier setzte das optische Verfahren der Forschergruppe QualiKorn zur Erkennung von Pilzschäden am Kornmaterial selbst an. Bereits mit der bildanalytischen Besatzanalyse wurden Indizien für Pilzschäden in Form von farblichen Veränderungen am Einzelobjekt gefunden.

Die selektivere und erfolversprechendere Methode zur Bestimmung von pilzinduzierten Kontaminationen ist die Einzelkornt transmissionspektroskopie, bei der jedes einzelne Objekt einer Stichprobe durchstrahlt wird und dabei die kornttransmitierende Strahlung detektiert wird. Um eine spektroskopische Einzelkornanalyse durchführen zu können, ist gegenüber den bildverarbeitungstechnischen Besatzanalyseverfahren im „freien Fall“ und „auf Band“ eine wesentlich andere Gestaltung der Strahlungsführung (Blende) als auch der Objektpositionierung erforderlich, die einen weiteren zweiten Versuchsaufbau notwendig machte.

Mykotoxinbestimmung mit Einzelkornt transmissionspektroskopie

Zahlreiche Lebensmittelskandale in den letzten Jahren haben dafür gesorgt, dass die Verbraucher immer größeren Wert auf eine hohe Qualität der Lebensmittel legen. Die größte Herausforderung bei der Getreide-Qualitätssicherung ist die Erkennung von Pilzschäden bereits am Kornmaterial. Während des Getreideanbaus kann es vorkommen, dass natürlich wachsende Schimmelpilze das Getreide befallen. Beim Wachstumsprozess der Pilze können toxische Stoffwechselprodukte (Mykotoxine) entstehen, die zur Kontamination der Getreideernte führen. Es existieren ca. 350 unterschiedliche Pilzarten, die Mykotoxine produzieren (vgl. [60]). Die am häufigsten in Mitteleuropa auftretenden Mykotoxine gehören zur Klasse der Trichothecene.

Verunreinigtes Getreide ist eine bislang unzureichend erforschte Vergiftungsquelle. Mykotoxine können beim Menschen zu schwerwiegenden Gesundheitsschäden führen. Neben den gesundheitlichen Risiken besteht eine weitere Folge des Pilzbefalls von Getreide darin, dass die Backqualität des Mehls beeinträchtigt wird. Mehl, welches aus belastenden Getreidekörnern produziert wurde, bildet ungewünschte Backeigenschaften aus. Das Ausmaß der Veränderung der Backeigenschaften wird durch die Pilzarten bestimmt (vgl. [3]; [52]; [11]).

Tückisch an Mykotoxinen ist, dass sie mit dem bloßen Auge nicht erkennbar sind. Der Pilz wächst im Inneren des Getreidekorns und muss nicht unbedingt zu Veränderungen an der Kornoberfläche führen. Ein augenscheinlich einwandfreies Weizenkorn kann bereits durch Mykotoxine befallen sein [53]. Deshalb sind risikoorientierte und systematische Getreideeingangskontrollen in den verarbeitenden Unternehmen von großer Bedeutung. Die Eingangskontrolle muss zur Gewährleistung eines sicheren Lebensmittels Pilzschädigungen nachweisen können. Das ermöglicht ein verbessertes Risikomanagement, da der gesamte spätere Prozess auf den Grad der Pilzschädigung abgestimmt werden kann. So können mehrere Reinigungsschritte zur Senkung der Pilzbelastung durchgeführt werden. Aufgrund fehlender geeigneter Messverfahren ist die Eingangsprüfung bisher verbunden mit hohen Kosten und einem Zielkonflikt zwischen Genauigkeit und Prüfdauer des chemischen Verfahrens.

Das in Deutschland am häufigsten vorkommende Mykotoxin ist Deoxynivalenol, kurz DON genannt. Durch die Verordnung EG 1881/2006 gilt seit dem Wirtschaftsjahr 2005/2006 der gesetzliche Grenzwert für DON von 1250 µg/kg in der Kategorie "Andere unverarbeitete Getreide als Hartweizen, Hafer und Mais". Getreideverarbeitende Betriebe wie z.B. Mühlen befinden sich seitdem in einer kritischen Situation. Sie müssen für die Einhaltung der gesetz-

lich vorgeschriebenen Grenzwerte garantieren, ohne jedoch geeignete Analysemethoden zur Verfügung zu haben.

Es fehlt ein schnelles, sicheres und wirtschaftliches Verfahren, welches auch in der hektischen Erntezeit DON-Analysen durchführen kann. Diese Betriebe befinden sich also in einer Grauzone, die bei drohenden Rückrufaktionen das wirtschaftliche Aus für diese Betriebe bedeuten könnte. Der gesetzliche Grenzwert wird jedoch bei einzelnen Kontrollen teilweise erheblich überschritten. Dies zeigt auch das Ergebnis der Kontrollen des Bundesministeriums für Ernährung, Landwirtschaft und Verbraucherschutz (Tabelle 4). Ein Gerät, welches ohne zusätzlichen Arbeitsaufwand automatisch den Toxingehalt einer Weizenprobe sicher abschätzen kann, stellt für die Mühlen ein ausgesprochen sinnvolles Werkzeug dar.

Tabelle 4: Vergleich der DON-Gehalte 2008 für Deutschland mit den Vorjahren (aus [5])

Getreide	Jahr	Probenzahl	Mittelwert	Median	Min. – Max.	90. Perzentil
Weizen	2001	253	246	69	<10 – 3528	722
	2002	261	239	136	<10 – 3616	563
	2003	457	148	51	<10 – 2692	308
	2004	505	268	109	< 10 - 3965	714
	2005	496	80	36	< 10 - 4097	180
	2006	471	88	16	< 10 - 7543	131
	2007	481	394	163	< 10 - 12249	763
	2008	468	70	16	< 5 - 2506	185
Roggen	2001	189	56	14	<10 - 1057	216
	2002	196	153	39	<10 - 4111	196
	2003	276	33	25	<10 - 495	63
	2004	274	145	35	< 10 - 3565	310
	2005	265	66	26	< 10 - 1672	166
	2006	263	32	< 10	< 10 - 1197	43
	2007	241	88	23	< 10 - 1606	183
	2008	276	29	17	< 7 - 467	63

Ann.: Die DON-Gehalte sind jeweils in µg/kg lufttrockenes Getreide angegeben. Die Ergebnisse wurden ab dem Jahr 2004 um die Wiederfindung korrigiert.

Daher wurde im Projekt QualiKorn untersucht, in welchem Maße es möglich ist, zeitlich aufwändige chemische Analysen durch schnellere optische Verfahren zu ersetzen. Als optisches Verfahren wurde dazu die spektroskopische Einzelkornmessung gewählt. Grundlegendes Prinzip ist die Transmissionsspektroskopie. Dabei wird das Korn im interessierenden Wellenlängenbereich durchstrahlt und die Transmissionsspektren werden aufgenommen. Dieses Verfahren besitzt den entscheidenden Vorteil, dass Pilzschäden nicht nur durch Bestimmung der Verfärbung auf der Oberfläche (typisch sind rötliche oder weißliche Verfärbungen) sondern auch durch Informationen aus dem inneren des Kornes detektiert werden können. Dies ist deshalb von hoher Bedeutung, da nicht nur die Oberfläche sondern der gesamte Kornkörper Pilzschäden aufweisen kann und diese im Inneren sogar zeitlich früher auftreten können.

Dazu wurde ein teilautomatisierter Aufbau zur Einzelkorntesttransmissionsspektroskopie mit zwei Spektrometern, ein Gerät für den Bereich des sichtbaren Lichts und eines für den Bereich des Nahen Infrarots, erstellt (siehe Abbildung 34). Die Anordnung der optischen Komponenten Lichtquelle, Feldblende, Lichtleitkabel und Spektrometer wurden kontinuierlich verbessert. Das folgende Bild (Abbildung 33) zeigt die Untersuchung eines einzelnen Kornes. Um Überbelichtung zu vermeiden, muss die Strahlung der Beleuchtungsquelle durch eine unterhalb des Kornes liegende Feldblende begrenzt werden. Es tritt damit nur noch Strahlung aus, die zwangsweise immer ein Korn durchstrahlt.



Abbildung 33: Durchstrahltes Korn

Für jedes Einzelkorn kann so eine spektroskopische Transmissionsmessung durch das verwendete Spektrometersystem durchgeführt werden. Dieses Verfahren ermöglicht Aussagen über stoffliche Veränderungen innerhalb des Korns. Dazu wurde ein hochwertiges Spektrometersystem für den Bereich von 400 bis 1700 Nanometer vom Projektpartner Carl Zeiss Micro Imaging Jena zur Verfügung gestellt. Um eine statistisch belegbare Aussage zu erhalten, ist es notwendig, eine möglichst hohe Anzahl von Körnern zu untersuchen.

Dazu wurde ein Lochraster für 2500 Körner hergestellt (siehe Abbildung 35). Die Positionierung des zu untersuchenden Korns erfolgte durch einen Zweikoordinatendirektantrieb.

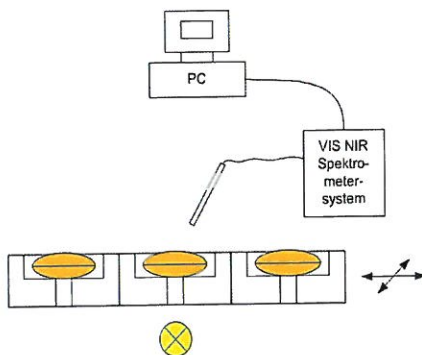


Abbildung 34: Grundprinzip der Einzelkorntransmissionsspektroskopie



Abbildung 35: Lochplatte für die Einzelkorntransmissionsspektroskopie

Zunächst musste ein Training des Klassifikators mit einzelnen gesunden und pilzgeschädigten Körnern erfolgen. Die Körner wurden manuell mittels Mikroskop ausgewählt und in die Fraktionen „pilzgeschädigte“ Körner (Myzel in der Keimfurche erkennbar) und „gesunde“ Körner (glatte Oberfläche, hohe Glasigkeit) eingeteilt. Anschließend wurde jedes Korn anhand seines Transmissionsspektrums bewertet und in die Klasse „gesund“ bzw. „pilzgeschädigt“ eingeteilt.

Nach Training des Klassifikators erfolgte die Auswertung von zu untersuchenden Getreideproben durch ein chemometrisches Modell mit zwei Hauptkomponenten (PLS-Regression). Jedes aufgenommene Einzelkornspektrum wird mit Hilfe des entwickelten chemometrischen Modells in zwei Zahlen überführt, in die Ergebnisparameter „Prediction“ und „Leverage“. „Prediction“ ist das Maß für die Klassenzugehörigkeit, „Leverage“ das Maß für die Ähnlichkeit mit den Trainingsdaten. „Prediction“ und „Leverage“ bilden einen neuen Merkmalsraum. Für die Auswertung wurde angenommen, dass eine Probe mit hohem Toxingehalt einen größeren Anteil pilzgeschädigter Körner enthält als eine Probe mit geringerem Toxingehalt. Ziel war es nun, eine Prognose des DON-Gehaltes einer Probe in Abhängigkeit des spektroskopisch detektierten Anteils „pilzgeschädigter“ Körner zu finden.




Abbildung 36: Merkmalsraum einer ausgewählten Probe mit 6000 ppb Deoxynivalenol

Es wurden 58 Proben mit bekanntem DON-Gehalt durch das Max Rubner-Institut zur Verfügung gestellt. Nach der spektroskopischen Messung aller Einzelkörner je Probe erfolgte die Einzelkornklassifikation aller Körner und die Berechnung der Anteile „pilzgeschädigter“ Körner aller Proben (beispielhaft für eine Probe in Abbildung 36 dargestellt). Die Wahl der Schwellwerte für „Prediction“ und „Leverage“ musste derart erfolgen, dass eine möglichst optimale Regressionsfunktion entsteht.

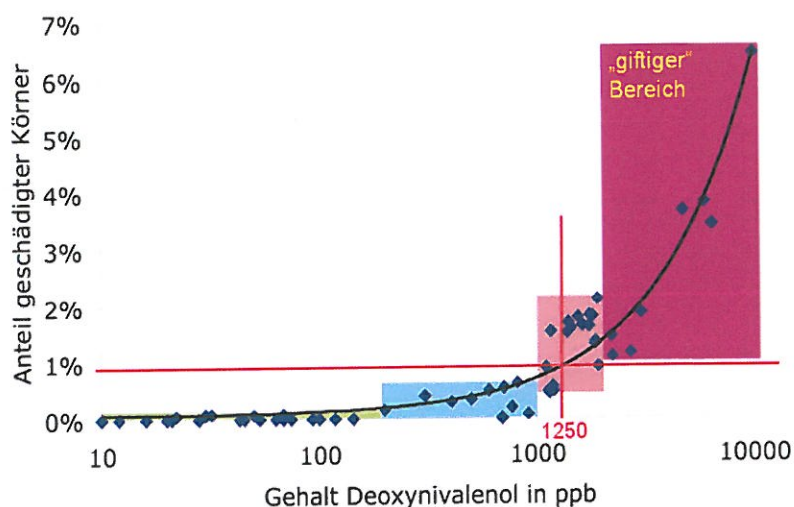


Abbildung 37: Regressionsmodell für den DON – Gehalt

Nach der Auswertung aller Proben wurde ein Regressionsmodell erstellt, das in der Abbildung 37 wiedergegeben ist. Die Gruppierung der einzelnen Probenwerte in der Nähe der Regressionsgerade zeigt, dass ein klarer Zusammenhang zwischen dem mit der Einzelkorntransmissionsspektroskopie bestimmten Anteil pilzgeschädigter Körner und dem, als Referenz chemisch ermitteltem DON-Gehalt besteht. Es sind allerdings noch Abweichungen erkennbar. Besonders im Bereich des Grenzwertes von 1250 ppb besteht bei einer rein optischen Unterscheidung noch eine Restunsicherheit. Diese kann durch einen größeren Probenumfang weiter gesenkt werden. Dazu wurde im Projekt eine automatisierte Vorrichtung konzipiert, die eine 100% Prüfung einer Getreideprobe mit 250g in einer Gesamtmesszeit von 15 min ermöglicht.

2) der wichtigsten Positionen des zahlenmäßigen Nachweises

In Tabelle 5 wird ein Überblick über die wesentlichen Positionen des zahlenmäßigen Nachweises gegeben.

Tabelle 5: Überblick über die wichtigsten Positionen des zahlenmäßigen Nachweises

Position Gesamtfinanzierungsplan	Bezeichnung	Entstandene Ausgaben insgesamt bis einschließlich 2010	Gesamtfinanzierungsplan
0812	Beschäftigte E 12 bis E15	823.042,86 €	827.872,00 €
0817	Beschäftigte E 1 bis E11	104.631,66 €	121.740,00 €
0820	Lohnempfänger	0,00 €	0,00 €
0822	Beschäftigungsentgeld	40.589,32 €	44.832,00 €
0831	Gegenstände bis 410 €	14.915,00 €	23.200,00 €
0834	Mieten und Rechnerkosten	10.445,63 €	10.800,00 €
0835	Vergabe von Aufträgen	48.484,00 €	48.484,00 €
0843	Sonst. allg. Verwaltungskosten	9.433,81 €	8.900,00 €
0846	Dienstreisen	18.989,44 €	17.068,00 €
0850	Investitionen	53.221,11 €	62.700,00 €
Summen:		1.123.752,83 €	1.165.596,00 €

3) der Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die Notwendigkeit der Förderung begründet sich in der technologischen Herausforderung des Projektes und in den damit einhergehenden technischen und wirtschaftlichen Risiken. Im Projekt wurden viele Bereiche neu erschlossen. Zu Beginn des Projektes wurden wesentliche Risiken bei der Umsetzungen der Vereinzelung der Getreideprobenbestandteile, der Bildaufnahme, der Beleuchtung, der Erkennungsalgorithmen und Erkennungsstrategien bereits erkannt und benannt. In der praktischen Durchführung stellte sich heraus, dass diese Risiken tatsächlich vorhanden waren aber in Komplexität und Umfang eher noch unterschätzt wurden. Besonders schwierig zu beherrschende Teilbereiche waren die mechanischen Anforderungen an die Vereinzelung und Bewegung des Messgutes bei Gewährleistung einer 100%-Prüfung des Messgutes und erkenntungstechnologisch notwendiger hoher Bildqualität, die Gestaltung der Farbbilderfassung mit hoher Geschwindigkeit und die Erreichung einer hohen Homogenität bei Beleuchtung und Abbildung. Ein weiteres großes Risiko lag auf dem komplexen Gebiet der Schaffung einer entsprechend leistungsfähigen Analysesoftware.

Die wissenschaftlich-technischen Ergebnisse zeigen, dass die Unsicherheiten im Projektverlauf überwunden und die Risiken berechenbar und beherrschbar wurden. Die umfassende wissenschaftliche Leistung ist auch aus der Tatsache heraus abzuleiten, dass im Projektverlauf zwei Dissertationen und zahlreiche andere Arbeiten entstanden. Ohne Förderung wäre dieses Ergebnis nicht zu erzielen gewesen. Das wissenschaftliche und wirtschaftliche Risiko wäre von keinem der Verbundpartner allein zu tragen gewesen. Das vorgestellte Gesamtergebnis konnte nur durch eine intensive Zusammenarbeit der Partner bei gleichzeitiger Förderung der Arbeiten erreicht werden.

4) des voraussichtlichen Nutzens, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans

Hauptziele des Projektes waren entsprechend des Verwertungsplanes die wissenschaftliche Verwertung der Ergebnisse durch die beteiligten Forschungseinrichtungen und die wirtschaftliche Verwertung der Ergebnisse durch die im Projekt mitarbeitenden Firmen. Die wissenschaftliche Verwertung der Projektergebnisse kann als außerordentlich gelungen be-

zeichnet werden. Durch die Arbeiten am Projekt erfolgte die Vertiefung und Intensivierung der Forschungsarbeiten ganz allgemein auf dem Gebiet der erkenntnistheoretischen Bildverarbeitung und speziell zur Qualitätssicherung von Naturprodukten im Fachgebiet Qualitätssicherung. Um den besonderen Fortschritt auf diesem Gebiet auch nach außen zu dokumentieren, wurde die Bezeichnung des Fachgebietes um die Bildverarbeitung ergänzt. Die geänderte Bezeichnung des Fachgebietes lautet: „Qualitätssicherung und industrielle Bildverarbeitung“ und weist damit die besondere Bedeutung der Bildverarbeitung in Forschung und Lehre des Fachgebietes aus. Herausragende Ergebnisse auf wissenschaftlichem Gebiet sind:

- Ausbau der Vorlesung „Digitale Bildverarbeitung 2“ mit dem Schwerpunkt Grundlagen und Anwendung der erkenntnistheoretischen Bildverarbeitung
- Abschluss von zwei Promotionen die unmittelbar aus dem Projekt hervorgegangen sind:

Anding, Katharina: Automatisierte Qualitätssicherung von Getreide mit überwachten Lernverfahren in der Bildverarbeitung. Dissertation, Technische Universität Ilmenau, erschienen im: ISLE-Verlag, ISBN 978-3-938843-54-3, September 2010,

Garten, Daniel: Einfluss von Bildaufnahme und Bildmerkmalen auf die Erkennungsgüte bei der automatischen Besatzanalyse von Brotweizen. Dissertation, Technische Universität Ilmenau, erscheint im: ISLE-Verlag, Juni 2011,

- Zahlreiche nationale und internationale Veröffentlichungen (Liste unter Punkt 6),
- Antragstellung zweier thematisch verwandter Nachfolgeprojekte aus dem Bereich des Machine Learnings, die bewilligt wurden:

„QualyScan“ Verbundprojekt TU Ilmenau, IPHT Jena, Carl Zeiss Jena, CZ Microimaging Jena, MSO GmbH Jena und Microfluidic ChipShop GmbH Jena,

„Autopetrographie- Bilderkennendes Verfahren für petrographische Prüfungen an mineralischen Korngemischen aus Lockergesteinslagerstätten“ Verbundprojekt TU Ilmenau, PST mbH & Co. KG Bernburg und GFE - Präzisionstechnik Schmalkalden,

Für die wirtschaftliche Verwertung der Ergebnisse sah der Verwertungsplan eine Übernahme und Vermarktung der Ergebnisse durch die Firma Brabender, Duisburg unter Zulieferung von Baugruppen durch das STZ Ilmenau und Carl Zeiss MicroImaging vor. Dieser Weg konnte so leider nicht beschritten werden, da es kurz vor Projektende zu einem Ausscheiden der Firma Brabender kam. Daher wurde der Weg beschritten, die Ergebnisse durch intensive Öffentlichkeitsarbeit und gezielte Ansprache bekannt zu machen, um einen neuen branchenbezogenen Hersteller zu finden. Hier läuft aktuell eine Reihe von Kontaktabmachungen zur weiteren Verwertung der Ergebnisse des Projektes und zur Überführung in ein Erzeugnis. In der Vergangenheit sind dies bzgl. im Einzelnen folgende Aktivitäten hervorzuheben:

- Ausstellungsexponat „Qualitätssicherung von Lebensmitteln“, Messe Sensor+Test; Nürnberg 2009,
- Vorstellung im Fernsehen zum Mühlentag 2009 (MDR) gemeinsam mit der Rolle-Mühle Waldkirchen (Sachsen),
- Vorstellung des Gerätes zur Jahrestagung des VDM (Verband deutscher Mühlen) am 20. Nov. 2009 in Würzburg,

- Ausstellungsexponat: „Automatische Besatzanalyse“ zur Messe Analytica, März 2010, München,
- Vorstellung des Gerätes in Bonn zu den Tagungen des Deutsche Maiskomitees (DMK) und Gemeinschaft zur Förderung der privaten deutschen Pflanzenzüchtung e.V. (GFP) November 2010,
- Ausstellung auf der Messe AGRA in Leipzig, Mai 2011: gemeinsamer Stand mit TU Dresden,
- Ausstellung auf der Messe Sensor +Test Nürnberg Juni 2011: Gemeinschaftsstand Sachsen/Sachsen-Anhalt/Thüringen, „Forschung für die Zukunft“,
- Kontaktaufnahmen zu Geräteherstellern in der Getreideverarbeitungsbranche.

Das Gerät „grainspector“ befindet sich in der praktischen Erprobung. Besonders interessant war der zweiwöchige Einsatz in der Firma GEKRA, da dort in großem Umfang manuelle Besatzanalysen durchgeführt werden. Das Gerät konnte nach Einweisung bereits von den Mitarbeiterinnen des Labors selbst bedient werden (Abbildung 38).



Abbildung 38: Grainspector im Laboreinsatz bei der Firma GEKRA, Querfurt

Nach Auswertung verschiedener Tests in unterschiedlich strukturierten Einrichtungen werden die sich je nach Branche (Bsp.: Getreideverarbeitung, Saatgutaufbereitung, usw.) deutlich unterscheidenden Anforderungen abgeglichen, um mit einem marktfähigen Gerät einen möglichst breiten Kreis an Nutzern erreichen zu können. Mit diesen Ergebnissen werden wir uns nochmals um Hersteller mit Marktzugang im Segment -Mühlen und Silobetriebe- bemühen.

5) des während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordenen Fortschritts auf diesem Gebiet bei anderen Stellen

Durch die regelmäßige Aktualisierung der Recherchen zum Stand der Technik konnten folgende, während der Projektlaufzeit erschienenen, relevanten Publikationen ausfindig gemacht werden:

1. Analyse von Durum

In [VEN2008] werden verschiedene Keimverfärbungen, gläserne Körner und Schmachtkörner von Durum unterschieden. Die Körner werden auf einer weißen Unterlage im Aufricht von einer Kamera betrachtet. Sich berührende Körner werden durch die Software separiert, was durch die ähnlichen Grundformen der Objekte praktikabel erscheint. Als Klassifikator wurden Naive Bayes und Lineare Diskriminanzanalyse untersucht. Eine Vereinzelmimik existiert nicht und das System kann nur ca. 100 Körner in einem Arbeitsgang erfassen.

2. Auswuchserkennung bei Weizen

Die Erkennung von Auswuchs wird in [NEE2007] untersucht. Hierzu wurden gesunde und auswuchsgeschädigte Weizenkörner mit Röntgenstrahlen abgebildet. Es wurden 55 Farb- und Texturmerkmale aus den Bildern extrahiert und neuronale Netze zur Klassifikation eingesetzt. Im Ergebnis konnten 90 % der geschädigten und 95 % der gesunden Körner korrekt erkannt werden. Durch Nutzung der Röntgenstrahlung ist es auch möglich, Auswuchs in frühen Stadien zu erkennen, wenn der Keimling noch nicht deutlich sichtbar hervortritt.

3. Einfluss der Feuchte auf morphologische Merkmale bei Weizen

Ein häufig vernachlässigtes Thema, nämlich der Einfluss der Feuchte auf die morphologischen Merkmale des Weizenkorns wird in [RAM2009] untersucht. Es wurden 4 kanadische Weizensorten untersucht. Die Werte der Basismerkmale wie Durchmesser, Flächeninhalt, längste Ausdehnung und mittlerer Radius nehmen mit steigendem Feuchtegehalt zu. Es besteht ebenfalls ein Einfluss auf die Momente und die Fourier Deskriptoren der Randkontur. In wie weit sich dies auf eine Klassifikation auswirkt, wurde nicht untersucht.

4. Analyse von Durum

Mittels multivariater Methoden und Bildverarbeitungsalgorithmen werden in [FAE2010] die Parameter Gelbfärbung, Dunkelfleckigkeit, Stippigkeit und Glasigkeit von Durumweizenkörnern bzw. -grieß bestimmt. Aussagen zu den verwendeten Bildmerkmalen und zur Bildaufnahmeeinrichtung wurden nicht getroffen. Erkennungsraten wurden ebenfalls nicht genannt.

5. Überwachung der Reinheit von Weizen im Mähdrescher

Mit Hilfe eines Hyperspektralsensors wird in [WAL2009] der Grad der Reinheit von Weizen in einer Erntemaschine überwacht. Hierbei werden 5 Bänder im Wellenlängenbereich von 400 bis 900 nm ausgewertet, um Stroh und ungedroschene Ähren zu erkennen und die Parameter der Erntemaschine entsprechend anzupassen, damit optimale Ergebnisse erreicht werden. Die Klassifikation erfolgt pixelweise und die Auswertung wird durch Betrachtung der Bereiche im Bild, welche von Stroh und Ährenteilen abgedeckt werden, realisiert. Für die Auswahl der geeigneten Spektralbänder wurden genetische Algorithmen verwendet.

Im Ergebnis konnte im Zeitraum vom 01.07.2007 bis 30.06.2010 kein Forschungsvorhaben mit direktem Bezug bzw. ähnlicher oder identischer Zielstellung zu den im Rahmen von QualiKorn geplanten und durchgeführten Arbeiten ausgemacht werden.

[VEN2008] Venora G., Grillo O. and Saccone: Quality Assessment of Sicilian Durum Wheat Storage Centers: Evaluation of Vitreous, Starchy and Shrunken Kernels using an Image AnalysisSystem. 2008, URL: <http://www.fromseedtopasta2008.it>, Aufruf: 20.12.2009.

[NEE2007] S. Neethirajan, D.S. Jayas, N.D.G. White: Detection of sprouted wheat kernels using soft X-ray image analysis, Journal of Food Engineering 81 (2007), S. 509–513.

[RAM2009] G. Ramalingam et. al.: Characterization of the Influence of Moisture Content on Single WheatKernels Using Machine Vision. CSBE/SCGAB 2009 Annual Conference, Rodd's Brudenell River Resort, Prince Edward Island, 2009.

[FAE2010] Qualitätsbewertung von Hartweizen, Hartweizengrieß und Hartweizenprodukten durch die Auswertung digitaler Bilder. Forschungsinformationssystem Agrar / Ernährung, URL: http://www.fisaonline.de/index.php?lang=dt&act=projects&p_id=2263, Aufruf: 10.07.2010.

[WAL2009] Wallays, C., Missotten, B., De Baerdemaeker, J., Saeys, W.: Hyperspectral waveband selection for on-line measurement of grain cleanness. Biosystems Engineering, 104 (1), 2009, S. 1-7.

6) der erfolgten oder geplanten Veröffentlichung des Ergebnisses, voraussichtlicher Nutzen, insbesondere der Verwertbarkeit des Ergebnisses und der Erfahrungen

Im Rahmen des Projektes QualiKorn konnten zahlreiche Ergebnisse in Form von nationalen und internationalen Veröffentlichungen publiziert werden. Der Erfolg ist insbesondere auch in den beiden im Rahmen des Projektes entstandenen umfangreichen Dissertationen [And 2010b], [Gar 2011] zu sehen. Nachfolgend sind die im Projekt entstandenen Publikationen aufgelistet.

12 Monografien/Artikel in Fachzeitschriften/Artikel in Tagungsbänden/Aufsatz in Sammelbänden/Hochschulschriften

- [And 2008]* Anding, Katharina; Garten, Daniel: Comparison of different classification algorithms at the application of automatical quality assurance of grain. In: Proceedings of the 53rd International Scientific Colloquium (IWK) of Ilmenau University of Technology, Faculty of Mechanical Engineering, Prospects in mechanical engineering. Ilmenau: ISLE, ISBN 978-3-938843-37-6. - 2008, S. 349-350.
- [Brü 2008]* Brückner, Peter; Anding, Katharina; Weißensee, Holger; Dambon, Martin: Digital Imaging for automatical Quality Assurance of Grain. In: Proceedings of the 53rd International Scientific Colloquium (IWK) of Ilmenau University of Technology, Faculty of Mechanical Engineering, Prospects in mechanical engineering. Ilmenau: ISLE, ISBN 978-3-938843-37-6. - 2008, S. 347-348.
- [Brü 2009a] Brückner, Peter; Anding, Katharina; Weißensee, Holger; Dambon, Martin: Quality Assurance of Grain with Colour Line Scan Cameras. In: OPTO 2009, Nürnberg, 2009, S. 139-144.
- [Brü 2009b] Brückner, Peter; Anding, Katharina; Dambon, Martin; Garten, Daniel: Automatisierte Besatzanalyse von Getreidestichproben. In: Mühle+ Mischfutter. Detmold: Verlag Moritz Schäfer GmbH & Co. KG, Nr. 21 (2009), S. 707-710.
- [Gar 2010a]* Garten, Daniel; Brückner, Peter; Linß, Gerhard: Image Acquisition and Image Features for the Automated Quality Assurance of Grain, In: Artificial

Intelligence and Applications (AIA) 2010, Innsbruck, Februar 2010.

- [And 2010a]* Anding, Katharina; Brückner, Peter; Linß, Gerhard: The Influence of Dataset Character on Classification Performance of Support Vector Machines at the Application of Wheat Analysis, Artificial Intelligence and Applications (AIA) 2010, Innsbruck, Februar 2010.
- [Brü 2010a] Brückner, Peter; Anding, Katharina; Dambon, Martin; Garten, Daniel: Automatisierte Bildanalyse zur Qualitätskontrolle von Getreide. IN: Transfer - Das Steinbeis Magazin, 01/2010, S. 4, URL: <http://www.stw.de/fileadmin/content/Transfermagazin/137067-2010-01.pdf>.
- [Mun 2010] Muntel, Timm; Anding, Katharina; Brückner, Peter; Dambon, Martin; Garten, Daniel: Automatisches Besatzanalysegerät für Getreide – grainspector. Poster auf: Analytica 2010, München, März 2010.
- [Brü 2010b] Brückner, Peter; Anding, Katharina; Dambon, Martin; Garten, Daniel: Measuring Wheat Quality. In: Vision Systems Design Magazine – Vision and Automation Solutions for Engineers and Integrators Worldwide, Vol. 15, Issue 6, Nashua, USA, June 2010.
- [And 2010b]* Anding, Katharina: Automatisierte Qualitätssicherung von Getreide mit überwachten Lernverfahren in der Bildverarbeitung. Dissertation, Technische Universität Ilmenau, erschienen im: ISLE-Verlag, ISBN 978-3-938843-54-3, September 2010.
- [Gar 2010b] Garten, Daniel; Anding, Katharina; Linß, Gerhard; Brückner, Peter: Automatische Besatzanalyse mittels Bildverarbeitung und maschinellem Lernen. In: 16. Farbworkshop 2010, Ilmenau, Oktober 2010.
- [Gar 2011]* Garten, Daniel: Einfluss von Bildaufnahme und Bildmerkmalen auf die Erkennungsgüte bei der automatischen Besatzanalyse von Brotweizen. Dissertation, Technische Universität Ilmenau, erscheint im: ISLE-Verlag, ISBN: 978-3-338843-54-3, Juni 2011.
- [Büt 2011]* Büttner, T.; Brückner, P.; Linß, G.: Prediction of Mycotoxin Contamination by Near Infrared Transmittance Spectroscopy of Wheat Kernels, 20th IMEKO TC2 Symposium on Photonics in Measurement, Linz, May 16th – May 18th, 2011.

* *betrifft referierte Zeitschriften oder Bücher, bei denen einer oder mehrere Experten des entsprechenden Gebietes den zur Veröffentlichung vorgeschlagenen Artikel bewerten (Peer-Review-refereed journals)*

6 Vorträge

- [And 2009a] Anding, Katharina; Brückner, Peter: Digitale Farbbildverarbeitung mit der Halcon Software – Machine Learning mit Halcon. Vortrag auf: 4. NEMO-SpectroNet Kollaboration Forum, URL: <http://www.spectronet.de>, Stuttgart, April 2009.
- [And 2009b] Anding, Katharina; Garten, Daniel: Bildgebende Verfahren für QS von Brotgetreide. Vortrag auf: 5. NEMO-SpectroNet Kollaboration Forum, URL: <http://www.spectronet.de>, Ilmenau, August 2009.
- [Gar 2010c] Garten, Daniel; Brückner, Peter; Linß, Gerhard: Image Acquisition and Im-

- [And 2010c] age Features for the Automated Quality Assurance of Grain. Vortrag auf: Artificial Intelligence and Applications (AIA) 2010, Innsbruck, Februar 2010. Anding, Katharina; Brückner, Peter; Linß, Gerhard: The Influence of Dataset Character on Classification Performance of Support Vector Machines at the Application of Wheat Analysis. Vortrag auf: Artificial Intelligence and Applications (AIA) 2010, Innsbruck, Februar 2010.
- [Lin 2010] Linß, Gerhard; Anding, Katharina: Automatic Image Analysis for Quality Control of Grain. Vortrag auf: 8. NEMO-SpectroNet Collaboration Forum, URL:<http://spectronet.de>, Jena, August 2010.
- [Gar 2010d] Garten, Daniel; Anding, Katharina; Linß, Gerhard; Brückner, Peter: Automatische Besatzanalyse mittels Bildverarbeitung und maschinellem Lernen. Vortrag auf: 16. Farbworkshop 2010, Ilmenau, Oktober 2010.

6 Diplom-, Bachelor- und Masterarbeiten

- [Wag 2007] Wagner, Sebastian: Konfiguration und Optimierung der Gerätetechnik zur optischen Qualitätssicherung von Getreideproben, 2007. - 146 S., Ilmenau, Techn. Univ., Diplomarbeit, 2007.
- [Sch 2008] Scholz, Stefan: Konzeption, Aufbau und Funktionsanalyse einer LED- Zeilenbeleuchtung zur optischen Qualitätsprüfung von Kleinteilen, 2008. - 134 S., Ilmenau, Techn. Univ., Diplomarbeit, 2008.
- [Hus 2008] Huschke, Dirk: Untersuchung und Umsetzung technischer Lösungen zum Transport und zur Sortierung von Kleinteilen, 2008. - 114 S., Ilmenau, Techn. Univ., Diplomarbeit, 2008.
- [Wie 2009] Wiens, Kornelius: Konzeption eines Demonstrators zur optischen Analyse von Kleinteilen, 2009. - 145 S., Ilmenau, Techn. Univ., Bachelor-Arbeit, 2009.
- [Pie 2010] Pieper, Gino: Methoden der Merkmalsselektion zur Realisierung einer Objekterkennung am Beispiel der automatisierten Erkennung von kleinen Objekten natürlichen Ursprungs, 2010. - 175 S., Ilmenau, Techn. Univ., Diplomarbeit, 2010.
- [Jos 2010] Jost, Stefan: Aufbau einer Versuchsanordnung zur Untersuchung von Getreideeinzelkörnern, 2010. - 84 S., Ilmenau, Techn. Univ., Bachelor-Arbeit, 2010.

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart Abschlussbericht
3a. Titel des Berichts Abschlussbericht zum Projekt QualiKorn – Bewertung und innovative Qualitätssicherung von Getreide mit lernfähiger automatisierter Bildanalyse unter Nutzung von spektralen, kontur- und texturorientierten Objektmerkmalen	
3b. Titel der Publikation	
4a. Autoren des Berichts (Name, Vorname(n)) Brückner, Peter; Anding, Katharina; Garten, Daniel; Lem, Steffen	5. Abschlussdatum des Vorhabens 30.06.2010
4b. Autoren der Publikation (Name, Vorname(n))	6. Veröffentlichungsdatum 10.05.2011
	7. Form der Publikation
8. Durchführende Institution(en) (Name, Adresse) Technische Universität Ilmenau, Ilmenau, Fakultät Maschinenbau, Fachgebiet Qualitätssicherung, Gustav-Kirchhoff-Platz 2, 98693 Ilmenau Max-Rubner-Institut Detmold, Institut für Sicherheit und Qualität bei Getreide, Schützenberg 12, 32756 Detmold	9. Ber.Nr. Durchführende Institution 03
	10. Förderkennzeichen *) 16 IN 0496
	11a. Seitenzahl Bericht 51
	11b. Seitenzahl Publikation 49
13. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Technologie (BMWi) 53107 Bonn	12. Literaturangaben 90
	14. Tabellen 6
	15. Abbildungen 38
16. Zusätzliche Angaben keine	
17. Vorgelegt bei (Titel, Ort, Datum) VDI/VDE Innovation + Technik GmbH, Bereich Innovation und Kooperation	
18. Kurzfassung Der Abschlussbericht umfasst die Ergebnisse des von 2007 bis 2010 durchgeführten und im Rahmen des InnoNet-Programms vom BMWi geförderten Forschungsprojektes QualiKorn. Ziel des Projektes war die Automatisierung der manuellen Besatzanalyse. Die Eingangskontrolle erfolgte bisher durch eine manuell-visuelle Analyse der äußeren Beschaffenheit der Getreide-Anlieferung durch erfahrene Laboranten oder Müllermeister. Dies ist eine sehr zeitaufwändige und subjektive Untersuchungsmethode. Die Aufgabe des Vorhabens bestand in der Entwicklung eines völlig neuen Verfahrens und eines gerätetechnischen Prototyps, welcher über bildanalytische Verfahren die Erkennung und Klassifizierung von einwandfreiem Grundgetreide und den Besatzfraktionen automatisiert durchführt. Das Prinzip der Bildaufnahme zur Besatzanalyse besteht in der vollständigen Erfassung der einzelnen Bestandteile der jeweiligen Getreideprobe mit einer 3-CCD-Farbzeilenkamera. Anschließend erfolgt der Prozess der maschinellen Erkennung. Grundlage der Erkennung bildet die Abbildung des Expertenwissens auf das Klassifikatormodell unter Verwendung eines umfangreichen Lerndatensatzes aus vorher selektierten und manuell klassifizierten Objekten. Bei diesem Erkennungsprozess werden bis zu 200 Merkmale verglichen und eine Aussage für jedes Objekt bzgl. seiner Klassenzugehörigkeit getroffen. Neben der Gewinnung eines geeigneten Merkmalssets zur Klassendifferenzierung spielte sowohl die Auswahl und Parameteradaption des Klassifikators als auch die Optimierung der Einflussfaktoren auf den Erkennungsprozess eine wesentliche Rolle. Für die Komplexität der gegebenen Multiklassen-Erkennungsaufgabe gepaart mit naturproduktbedingter hoher Intraklassenvariabilität bei gleichzeitig geringer Interklassenvariabilität konnte eine sehr gute Erkennungsgenauigkeit erzielt werden. Für die Kornbewegung konnten zwei technische Prinzipien, „Freier Fall“ und „Auf Band“ erarbeitet und umgesetzt werden. Ein weiteres Ziel des Projektes war die Detektion von Mykotoxinen. Dazu entstand ein separater Versuchsaufbau für die Einzelkornmessung. Es konnte nachgewiesen werden, dass durch die Erkennung pilzgeschädigter Körner mittels Transmissionspektroskopie im VIS- und NIR-Bereich eine Vorhersage über den Gehalt an Mykotoxinen (DON) möglich ist. Die Zielvorgabe des Projektes, eine Getreideprobe im Umfang von 500g innerhalb von 10 Minuten vollständig zu analysieren, wurde erreicht. Der Besatzanalyse-Prototyp mit dem Namen „grainspector“ wurden in Mühlen und Silobetrieben erfolgreich erprobt. Die Ergebnisse des Projektes wurden umfassend publiziert und auf mehreren Messen ausgestellt.	
19. Schlagwörter Besatzanalyse, Automatisierung, Bildverarbeitung, Erkennung, CCD-Zeilenkamera, Erkennungsraten, Getreide, Qualitätssicherung, Pilzschaden, Spektrometer, Mykotoxine, Deoxynivalenol	
20. Verlag -	21. Preis -

*) Auf das Förderkennzeichen des BMWi soll auch in der Veröffentlichung hingewiesen werden.

Document Control Sheet

1. ISBN or ISSN	2. Type of Report final report
3a. Report Title final report to the project „QualiKorn“ – valuation and innovative quality assurance of grain with adaptiv automatically image analysis under utilization of spectral, shape and texture features	
3b. Title of Publication	
4a. Author(s) of the Report (Family Name, First Name(s)) Brückner, Peter; Anding, Katharina; Garten, Daniel; Lerm, Steffen	5. End of Project 03.06.2010
4b. Author(s) of the Publication (Family Name, First Name(s))	6. Publication Date 10.05.2011
	7. Form of Publication
8. Performing Organization(s) (Name, Address) Ilmenau University of Technology, Faculty of Mechanical Engineering, Department of Quality Assurance, Gustav-Kirchhoff-Platz 2, 98693 Ilmenau Max-Rubner-Institut, Department of Safety and Quality of Cereals, Detmold, Schützenberg 12, 32756 Detmold	9. Originator's Report No. 03
	10. Reference No. 16 IN 0496
	11a. No. of Pages Report 51
	11b. No. of Pages Publication 49
	12. No. of References 90
13. Sponsoring Agency (Name, Address) Bundesministerium für Wirtschaft und Technologie (BMWi) 53107 Bonn	14. No. of Tables 6
	15. No. of Figures 38
16. Supplementary Notes	
17. Presented at (Title, Place, Date) VDI/VDE Innovation + Technik GmbH , Department Innovation and Cooperation	
18. Abstract The final report includes the results of the research project done from 2007 to 2010 funded by BMWi within the InnoNet-Program. The aim of the project was the automation of the manual Besatz analysis. The input control was previously done by a manual-visual inspection of the physical quality of grain by experienced laboratory assistants or leading millers. This is a very time-consuming and subjective method of examination. The task of the project was to develop a completely new procedure and a technical prototype device for an image based detection and classification of basic cereals and Besatz fully automatic. The principle of image analysis for the Besatz analysis is the complete registration of all individual components of each grain sample with a 3-CCD color line scan camera, followed by the process of automatic recognition. The basis of the recognition is formed by the representation of expert knowledge on the classifier model using a large training data set of previously manually selected and classified objects. During this process, up to 200 features are compared to make a statement for each object with respect to its class membership. In addition to attracting a suitable feature set for class differentiation also the selection and adaptation of the classifier parameters and the optimization of the factors that influence the recognition process played a decisive role. For the complexity of the given multi-class recognition task coupled with natural products-related high intraclass variability with relatively small inter-class variability, a very good recognition accuracy could be achieved. For the sample object motion, two technical principles, "Free Fall" and "On-Conveyor" were developed and implemented. Another objective of the project was the detection of mycotoxins. There for a separate test set was created for the single particle measurement. It could be shown that by detecting fungus-damaged seeds by transmission spectroscopy in the VIS and NIR range prediction of the presence of mycotoxins (DON) is possible. The objective of the project, to analyze a grain sample of 500g within 10 minutes has been fully achieved. The Besatz analysis prototype called "grainspector" has been tested successfully in mills and grain storage facilities. The results of the project have been published extensively and exhibited at several exhibitions.	
19. Keywords Analysis of Besatz, automation, image processing, color image processing, recognition, ccd line camera, rate of recognition, grain, quality assurance, fungal damage, spectrometry, fungal toxin, deoxynivalenol	
20. Publisher -	21. Price -