

Prozessintegrierte, bildgestützte Echtzeit-Farbklassifikation und Produktprüfung in der Massen- produktion von Kunststoffflaschen

Maik Gollnick, Aleksandr Sobolyev, Daniel Herfert, Lothar Paul

Gesellschaft zur Förderung angewandter Informatik e.V. (GFaI),
Volmerstraße 3, 12489 Berlin

eMail: gollnick@gfai.de

URL: <http://www.gfai.de>

Im vorliegenden Beitrag wird ein echtzeitfähiges, bildgestütztes, prozessintegriertes System zur flexiblen 100%-Kontrolle von Farb-, Reflektanz- und Transluzenz-Eigenschaften in der industriellen Serienfertigung von Kunststoffflaschen vorgestellt. Die Lösung basiert auf Farbbildauswertung, Standard-Industriekameras und einer flexiblen Teach-Prozedur für die Klassifikation der jeweils vereinbarten Gut-Muster. Dargestellt werden Einzelheiten der genutzten Sensor-, Beleuchtungs- und der technischen Realisierung insgesamt, die genutzten Algorithmen werden vorgestellt und Aspekte der softwaretechnischen Realisierung angesprochen. Das Gesamtsystem wurde unter realitätsnahen Bedingungen getestet und befindet sich seit einigen Wochen im industriellen Dauertestbetrieb. Erste Ergebnisse des Einsatzes in der realen Massenproduktion werden bis zur Workshop-Präsentation erwartet.

1 Einleitung / Motivation

In vielen industriellen Fertigungslinien wird auf eine Inline-Farbprüfung verzichtet, da die Farbgebung in gesonderten, technisch gut abgesicherten Prozessschritten (Beschichten / Lackieren am Ende des Prozesses) erfolgt und die Prüfung der optischen Eigenschaften an eine externe Qualitätssicherung / Endkontrolle ausgelagert werden kann. Teilweise stehen aber auch die hohen Anforderungen an die technische Realisierung, bekannte Schwierigkeiten einer objektiven Farbmessung im Prozess oder die Stabilität der Prüfqualität einer prozessintegrierten Farbprüfung entgegen. In einigen hochintegrierten Fertigungslinien wie denen von Kunststoff-

oder auch Textilprodukten ist die Farbprüfung dagegen ein essentieller Bestandteil der Fertigung selbst. Der Zusammenhang bzw. Einfluss von einer Vielzahl von Prozessparametern und Störgrößen auf die resultierende Farbe bei der Produktion ist oft schwer formalisierbar oder nicht bekannt. Eine ständige und echtzeitfähige Kontrolle der Farbeigenschaften ist dann von hoher Relevanz, um während der Fertigung tendenzielle oder periodische auftretende Farbabweichungen zu erkennen und den Prozess entsprechend korrektiv zu steuern.

2 Konzept und technischer Aufbau

Anlage und Lösungskonzept

Ausgangspunkt der technischen Konzipierung des Systems war die Analyse der Randbedingungen in einem konkreten, hochautomatisierten Fertigungsprozess bei einem führenden Hersteller von Kunststoffflaschen (ALPLA Werke Alwin Lehner GmbH & Co KG, Abb. 1). An den Fertigungs-
linien ist mit einem Durchsatz von ca. 6-10 Flaschen pro Sekunde zu rechnen, damit kann eine 100%-Farbprüfung nur im dynamischen Regime, d.h. ohne ein Stoppen oder Ausgliedern einzelner Prüfobjekte realisiert werden.



Abbildung 1: Prototyp der Farbprüfanlage PROFAKO an einer Produktionslinie der Firma ALPLA

Ungeachtet der im Prozess ausschließlich auftretenden und als Produkteigenschaft auch geforderten Einfarbigkeit der Flaschen (eine integrale Prüfung der Farbe über einen größeren Teil der Oberfläche ist damit ausdrücklich erwünscht), weisen die gefertigten Produkte ein breites Spektrum hinsichtlich Größe und Form auf. Darüber hinaus wurde schnell klar, dass die Flaschen aufgrund der Herstellung im Spritzgießverfahren oder Streckblasverfahren-Verfahren (aus Granulatmischungen oder durch Aufblähen sogenannter Präformlinge) nicht nur verschiedenste Farbtöne und Transluzenzgrade aufweisen können, sondern dass ihr optisches Erscheinungsbild und ihre Reflektanzeigenschaften durch einen möglichen Mehrschicht-Aufbau zusätzlich komplex beeinflusst sind. Der Vergleich mit physisch vorliegenden Farbmustern, die einmal mit den Abnehmern vereinbart werden, erfolgt bisher stichprobenartig mittels visueller Inspektion durch Mitarbeiter der Qualitätskontrolle. Es wurde schnell klar, dass eine auf Absolut-Sollwerte orientierte 100%-Farbprüfung unter den gegebenen Bedingungen gegenwärtig nicht realisierbar ist. Konzipiert wurde dagegen ein Zwei-Kammersystem für Auflicht- und Durchlichtprüfung mit der Maßgabe, dass eine Gut-Schlecht-Klassifikation für jedes Produkt anhand des Einlernens von Merkmalen jeweilig vereinbarter Gut-bzw. Schlecht-Musterflaschen erfolgen soll. Hieraus folgt auch, dass eine solche Entwicklung für das industrielle Umfeld auch die Realisierung schneller und einfacher Teach-Prozeduren umfassen muss, die ein

eingewiesener Einrichter ohne wissenschaftlichen Background in der kurzen Zeit des Sortenwechsels an der Linie ausführen kann.

Hardware

Um die erforderliche hohe Flexibilität des vorgestellten Prüfsystems hinsichtlich des Erfassungsbereichs und der Prüfparameter zu erreichen, werden in den Messkammern relativ unspezifische Sensoren (zwei industrielle Color-Matrixkameras Typ AVT GC650C, GigaBit Ethernet Interface) eingesetzt. Als weitere aktive Elemente kommen eine weiße Dome-Beleuchtung (CCS HPD-150) im Auflicht- sowie eine fokussierbare LED-Spotlight-Quelle (HLV2 Series) im Durchlichtsektor zum Einsatz, die mittels einer Synchronisations- und Steuereinheit sowohl gedimmt als auch geflasht werden können. Als Impulsgeber werden je eine Reflexions-Lichtschanke pro Kammer genutzt, die auf die Vorderkante der auf dem Förderer vorbeigeführten sogenannten Formatschuhe (eine Art standardisiertes Transport-Hilfsmittel für die Produkte auf dem Förderer) triggern. Die Kammern sind durch eine lichtundurchlässige schwarze Blende voneinander getrennt und durch ein geschlossenes Gehäuse mit Lichtfallen an Ein- und Auslauf des Förderbandes auch von Umgebungslichteinflüssen isoliert.




Abbildung 2: Systemaufbau, Sensor- und Hardwaremodule des Prüfsystems

Das eingesetzte Equipment wird komplettiert durch einen leistungsstarken lüfterlosen Industrie-PC aus der NISE-Serie (zunächst Core i2, inzwischen Core i7), zwei elektrisch betriebene Stopper, die im Teach-Modus wahlweise auch eine statische Bildaufnahme ermöglichen sowie eine Signalampel, die ebenso wie die anderen Baugruppen (Kameras, Lichtsteuerung) über eine GigE-Verbindung angesprochen wird.

Software / Softwarearchitektur

Zur Online-Farbprüfung wurde eine modulare Software mit Namen „Color Inspector“ entwickelt.

Ablauf und implementierte Module der realisierten Software sind schematisch in Abb. 3 dargestellt. Bilderfassung, -vorverarbeitung, die Selektion der zu prüfenden Objektbereiche sowie die Merkmalsextraktion erfolgen nach einer flexiblen Szenario-Steuerung für jede Kammer separat, die extrahierten Merkmalsvektoren werden in einem Klassifikatormodul ausgewertet. Ausgangsseitig wurde eine reduzierte Online-Visualisierung auf dem Touchscreen sowie die Möglichkeit der Fehlersignalisierung (Ampel) oder Aktoren-Ansteuerung (Ausschleusung) umgesetzt. Weiterhin sind konfigurierbare Langzeit-Protokolle und die Berechnung von Langzeit-Statistiken implementiert.




Abbildung 3: Schematische Darstellung des Prüfablaufs

Die als Linux-Applikation realisierte Softwarearchitektur entspricht der in Abb. 3 dargestellten Modularisierung. Die einzelnen Ablaufschritte sind als separate und somit leicht austauschbare Module (Plugins) implementiert, um eine einfache und flexibel an die Objekte bzw. Prüfaufgabe angepasste Konfigurierbarkeit zu erreichen. Dabei wird das prozessintegrierte Prüfprogramm von zuvor eingerichteten „Szenarien“ gesteuert, die als xml-Datei geladen werden. Die Szenario-Dateien enthalten nicht nur die Parameter der Module, sondern auch die Auswahl der im Prüfprozess zu nutzenden algorithmischen Module selbst. Jedem verfügbaren Modul ist in der xml-Struktur ein Knoten zugeordnet, unter welchem dieses Modul eigene Parameter verwaltet. Struktur und Inhalt der Parameter im betreffenden xml-Knoten sind streng modulbezogen angelegt, sodass für Auswahl, Substitution oder Hinzufügen einzelner Module keine Änderungen im Hauptprogramm erforderlich werden.

Um die Szenarien zu erstellen, zu editieren bzw. schnell aufgabengerecht anzupassen (→ Teach-Prozedur), wurde das separate Programm „Scenario Editor“ geschaffen, das konsequenterweise dieselben Plugins nutzt wie das Prüfprogramm selbst. Da so für jede Teilaufgabe nach Abb. 3 ohnehin mehrere Module (Plugins) existieren können, stellt auch die Erweiterung des Systems durch neue Algorithmen kein Problem dar. Um die Systemkonfiguration durch einen Einrichter in der Produktion effektiv an die wechselnden Objekte und Prüfaufgaben anzupassen, bietet der Scenario Editor jeweils eine plausible Auswahl von Modulen an und schlägt während der Teach-Prozedur optimierte Einstellungen für die dann vorliegende Produktklasse (Prüfobjekt) vor.

3 Bildkorrektur und Bildanalyse

Aufgrund der oben beschriebenen modularen Struktur des Frameworks können verschiedene Verfahren zur Bildkorrektur bzw. Analyse eingesetzt bzw. ausgewählt werden. Zurzeit stehen hierfür folgende Module zur Verfügung:

Bildkorrektur

Die Bildkorrektur stellt die Grundlage für die anschließende Bildanalyse beziehungsweise für die Klassifikation der Farbinformationen dar. Die Kameras in beiden Lichtkammern (Auflicht, Durchlicht) sind mit jeweils einem Kalibrierungskörper, der das Referenzweiß für den automatischen Weißabgleich enthält, bezüglich der kammerspezifischen Lichtquellen kalibriert. Der Abgleich geschieht dann über den „Gray-World“-Algorithmus [1] unter Verwendung der Bilddaten von den erfassten Kalibrierungskörpern.

Segmentierung / Detektion des Prüfobjekts

Nachdem die Kameras auf die Prüfbeleuchtung eingestellt wurden, erfolgt die Segmentierung des Eingangsbildes. Da kein Verfahren gefunden wurde, das sich für alle in Frage kommenden Prüfobjekte durchgängig als geeignet erwies, wurden drei Methoden implementiert, die für ein gegebenes Szenario alternativ auswählbar sind:

1. Im ersten Ansatz wird die absolute Differenz zum Hintergrund der jeweiligen Lichtkammer genutzt. Alle Differenzen oberhalb eines Schwellwertes werden hierbei als Vordergrund und alle Differenzen unterhalb eines Schwellwertes als Hintergrund festgelegt. Zur Differenzbildung wird die Intensität der jeweiligen Bilder herangezogen, wodurch keine weiteren Annahmen über die Objektform oder Farbe notwendig sind.
2. Im zweiten Ansatz wird angenommen, dass sich das Objekt in der Bildmitte befindet (diese Situation kann aufgrund der Lichtschranken-Triggerung der Bildaufnahme vorausgesetzt werden). Die Farbinformation wird aus einem festgelegten, am Bildmittelpunkt zentrierten Bereich ausgelesen. Die minimalen beziehungsweise maximalen Farbwerte dienen anschließend als globale Schwellwerte zum Segmentieren des gesamten Bildes.

3. Kann mit keinem der genannten Ansätze eine Segmentierungsfläche mit ausreichender Sicherheit gefunden werden, besteht die Möglichkeit, Schwellwerte für den Lab-Farbraum anhand realer Bilder von Prüfobjekten manuell festzulegen. Nur wenn sich auch das nicht als zielführend erweist, wird die Szenarioerstellung für den vorliegenden Objekttyp abgebrochen bzw. zurückgewiesen.

Positionskorrektur

Aufgrund der realen Dynamik des Flaschentransports (inklusive möglicher abrupter Stopps oder Beschleunigungen) im Fertigungsprozess erwies es sich als unumgänglich, eine Prüfung der Flaschenposition im Bild und eine Nachführung der „Region of Interest“ (ROI) vorzusehen. Dabei wird die Ausrichtung der segmentierten Region einer Modellflasche als Referenz angenommen. Anschließend werden alle anderen Regionen bezüglich dieser Referenz transformiert. Die Ausrichtungen zweier Flächen zueinander lässt sich über die Bildmomente und einer affinen Abbildung modellieren [8].

Automatisierte Regionswahl

Nach der Segmentierung werden für die Klassifizierung geeignete Regionen auf der Objektabbildung ausgewählt und störende Bildregionen ausgeschlossen. Solche können entweder durch den Segmentierungsalgorithmus oder durch Benutzeraktivitäten (bei manueller Schwellwert-Einstellung) entstehen. Außerdem treten aufgrund der Dynamik des Förderbandes Licht- und Schatteneffekte auf, die die Farberkennung erheblich beeinflussen können.

Zur Auswahl und Festlegung für die Klassifikation relevanter und bzgl. der Dynamik stabiler Bildbereiche wird ein Optimierungsverfahren (genetischer Algorithmus [16][17]) eingesetzt. Es wurde sich für ein stochastisches Optimierungsverfahren entschieden, da hohe Anforderungen bzgl. der Laufzeiteigenschaften und der Größe des Lösungsraumes vorliegen. Der strukturelle Aufbau des Verfahrens wird im Folgenden vorgestellt. Dabei wird auf die Festlegung des Lösungsraumes, das Finden einer optimalen Startpopulation und die verwendete Fitnessfunktion Bezug genommen.

Definition des Lösungsraumes

Zur Definition des Lösungsraumes wird eine Gitterstruktur (Grid) innerhalb des segmentierten Bildbereiches (zentriert am Mittelpunkt) erzeugt. Durch eine einstellbare Detaillierung des erzeugten Grids (Größe der einzelnen quadratischen Regionen von 1 bis N Pixel) kann entweder jeder Bildpunkt oder ein zusammengefasster Bildbereich durch das Verfahren bewertet werden. Mit der Größe des Gitters werden gleichzeitig die Komplexität und damit die notwendige Ausführungszeit sowie die Genauigkeit gesteuert. Die einzelnen Regionen der Gitterstruktur werden als Gene und deren Belegung als Allele angesehen und die Kombination von mehreren Regionen als Individuum (mögliche Lösung). Für das Optimierungsverfahren werden mehrere Individuen (Lösungskandidaten) in eine

Population zusammengeführt, aus denen das optimale Individuum iterativ (über mehrere Generationen) bestimmt wird.

Definition der Fitnessfunktion

Der Fitnessfunktion wird in jedem Verfahrensschritt eine binäre Maske (Individuum) übergeben, deren Belegung (Allele) die Aktivierung bzw. Deaktivierung der einzelnen Gitterelemente (Gene) steuert. Basierend auf dieser Auswahl wird in der Fitnessfunktion ein Gütemaß bestimmt, indem für jedes Eingabebild der Gut- und Schlechtmuster (ggf. auch andere Klassen möglich) der Merkmalsvektor aus den zur Verfügung stehenden Bildpunkten errechnet wird. Die so entstehenden Gitterelement-Gruppen werden anschließend hinsichtlich der erreichbaren Klassifizierungsqualität (eindeutig zu trennende Cluster) bewertet.

Da die Klassifikation für unbekannte Szenarien konzipiert wurde, können ad-hoc keine Annahmen über die Clusterverteilung oder die Kompaktheit getroffen werden. Um einen stabilen Praxiseinsatz zu gewährleisten, muss darüber hinaus eine Überanpassung an die verwendeten Gut- und Schlechtmuster vermieden werden.

Die Modellierung der Fitnessfunktion wurde daher sehr allgemein gehalten und beinhaltet als Gütemaß die Summe aller Distanzen der Merkmalsvektoren eines Clusters zu den Vektoren aller anderen Cluster. Somit werden Individuen bevorzugt die eine größtmögliche Trennung bzgl. der Farbeigenschaften zwischen Gut- und Schlechtmustern ermöglichen. Das Ziel des Optimierungsalgorithmuses ist das Maximieren der Distanzen zwischen den Clustern der Gut- und Schlechtmuster (2-Klassenproblem) bzw. mehrerer Klassen.

Wahl der Startpopulation

Der erste Schritt des genetischen Algorithmus ist die Generierung der Startpopulation. Üblicherweise werden hierfür zufällig Individuen aus dem Lösungsraum gewählt. Prinzipiell ist es auch möglich, die Startpopulation mit gemäß der Fitnessfunktion „guten“ Individuen zu belegen. Dabei geht man jedoch das Risiko ein, dass diese sich durchsetzen, obwohl sie zu einem lokalen Optimum führen können. Zum Generieren der Startpopulation werden die Gitterregionen aller verwendeten Eingabebilder (für alle Farbklassen) in den Lab-Farbraum transformiert. Anschließend wird jedes Gitterelement durch die Summe der Standardabweichungen im L-, a- und b-Farbkanal beschrieben. Die Größe des Wertes spiegelt die Konstanz der Farbe sowie die Homogenität der Beleuchtung wieder. Daher werden die Regionen nach ihren Werten aufsteigend sortiert. Die erste Hälfte der Sortierung bildet anschließend die Grundmenge für eine zufällige Auswahl der Startpopulation.

4 Farbklassifikation

Die optimale Auswahl von Merkmalen bzw. die Konfiguration von Merkmalsvektoren ist maßgeblich für die Güte der späteren Klassifikation. Durch die verwendete Sensorik steht eine relativ große Anzahl von möglichen Merkmalen

für die Klassifikation zur Verfügung. Zur Auswahl von klassifikationsrelevanten Merkmalen wurden zunächst die Farbeigenschaften durch die statistischen Momente in den Farbräumen RGB, HSV und Lab beschrieben und mit dem „Fisher-Score“-Algorithmus [15] bewertet. Dabei stellte sich heraus, dass für die zugrunde liegenden Bilddaten und die verwendeten Farbmuster das arithmetische Mittel und die Standardabweichung für die Farbkanäle des Lab-Farbraumes als stabile Merkmale ausgewählt werden können.

Der daraus resultierende Vektor spiegelt die maximale Dimension des Merkmalsraumes wieder (6 Dimensionen). Die Signifikanz der einzelnen Merkmalskandidaten ist objektabhängig (abhängig vom zu prüfenden Werkstück) und die Verwendung der Merkmale muss demzufolge flexibel ausgelegt sein und für einen Werkstücktyp nach Möglichkeit beim Einrichten des Systems automatisch und ohne Expertenwissen adaptiert werden.

Für den Praxiseinsatz erwies sich der Lab-Farbraum aufgrund zweier wesentlicher Vorteile als geeignet. Zum einen orientiert sich der Farbraum an der Wahrnehmung der Farben durch das menschliche Auge und enthält alle Farben die der Mensch unterscheiden kann. Zum anderen können Farbunterschiede durch die ΔE -Metriken für den empfundenen Farbabstand gemessen und zur Klassifikation von Gut- und Schlechtmustern, sowie der Abgrenzung gegenüber anderen Farbnuancen genutzt werden. Speziell bei der Farbtrennung wurden für unbunte Farben die ΔS -Metrik und für bunte Farben die ΔE_{76} -Metrik genutzt. Für die Unterscheidung gegenüber Fremdfarben wird die ΔE_{cmc} -Metrik mit vordefinierten Grenzwerten eingesetzt. Generell wurden alle gängigen ΔE -Metriken (ΔE_{76} , ΔE_{94} , ΔE_{cmc} und ΔE_{00}) implementiert und können im Szenario genutzt werden.

Da die Herstellung und Bewertung von Schlechtmustern durch die Qualitätssicherung aufwendig und zeitintensiv ist, steht zum Einlernen der Farbklassen nur eine kleine Menge an Beispielen pro Klasse (z.B. Gut- und Schlechtmuster) zur Verfügung. Daher wurde zur Trennung innerhalb einer Farbnuance der „k-Nearest-Neighbor“-Algorithmus (kNN) [13] als statistischer Verteilungsklassifikator ausgewählt, da dieser eine praktische ausreichende Klassifikationsgüte auf den vorliegenden Daten erreichte und durch die Auswahl der nächsten Nachbarn dynamisch auf die Menge der vorliegenden Trainingsbeispiele angepasst werden kann. Zudem ist das Verfahren robust gegenüber Ausreißern und bietet unter den gegebenen Voraussetzungen eine schnelle Ausführungszeit.

Aufgrund der verschiedenen Transluzenzgrade sind nicht immer beide in den Kammern verfügbare Beleuchtungsarten zur Klassifikation geeignet, ihre Einbeziehung kann das Klassifikationsergebnis sowohl verbessern als auch verschlechtern. Neben der Farbtrennung übernimmt deshalb der Klassifikator auch die Aufgaben von Bewertung und Auswahl der geeignetsten Lichtkammer oder Kammerkombination. Für wenig oder nicht transluzente Flaschentypen ist die Durchlichtprüfung nicht geeignet, da keine beziehungsweise wenig Bildpunkte zur Klassifikation

genutzt werden können. Daher wurde die Größe der segmentierten Fläche als weiteres Merkmal zur Bewertung der Lichtkammern herangezogen.

Im Gegensatz dazu ist bei stark transluzenten Flaschen das Auflicht oft nicht aussagekräftig, da der Hintergrund zu stark beleuchtet wird und somit als ungewolltes Merkmal die Klassifikation beeinflusst. Für diesen Fall konnte bisher kein Automatismus gefunden werden, sodass nur ein genereller Verwendungshinweis an den Benutzer gegeben wurde. Für Flaschentypen, die unter beiden Beleuchtungsarten eine ausreichend gute Segmentierung erreichen, wird die Klassifikationsrate der verwendeten Trainingsbeispiele berechnet und als Gütemaß für die jeweilige Lichtkammer genutzt. Liegt die ermittelte Rate unterhalb einer vordefinierten Schranke (experimenteller ermittelter Schwellwert), so wird die dazugehörige Kammer ausgeschlossen.

5 Ergebnisse

Die Gut- und Schlechtmuster zum Validieren des Klassifikators und der eingesetzten Bildverbesserungsverfahren wurden durch die Firma ALPLA Werke Alwin Lehner GmbH & Co KG in Form von Plastikflaschen bereitgestellt. Dabei enthielten die verwendeten Flaschentypen einen durchgängigen Farbton (einfarbig) und zeichneten sich durch unterschiedliche Formen (Formbezeichnung Std 10, 16) und einen unterschiedlichen Transluzenzgrad aus. Anhand der Transluenzeigenschaften der jeweiligen Kunststoffschichten wurden entweder beide Lichtkammern oder nur die Auflicht- beziehungsweise Durchlichtkammer genutzt (siehe Abschnitt Farbklassifikation). Der Unterschied zwischen den Farbklassen wurde hierbei zum einen durch eine Variation des Farbtönen und zum anderen durch eine Veränderung der Anzahl und der Zusammensetzung der Kunststoffschichten bei der Herstellung erzeugt. Darüber hinaus unterteilten sich die zugrunde liegenden Muster in bunte und unbunte Farben. Für die Ermittlung der Klassifikationsraten wurden die vorhandenen Gut- und Schlechtmuster für jeden Flaschentyp in eine zufällig erzeugte Trainings- und Validierungsmenge (50:50) aufgeteilt. Dieser Schritt wurde mehrmals wiederholt und abschließend das arithmetische Mittel über allen Wiederholungen gebildet. Für die Evaluierung wurde der GFaI ein Flaschenband (als Zyklus) bereitgestellt. Alle hier genannten Ergebnisse des Prüfsystems beziehen sich auf die Auswertung am Fertigungsband in der GFaI.

In der ersten Auswertung (Tab. 1) wurden die drei Farbräume RGB, HSV und Lab mit den jeweiligen Merkmalen Minimum, Maximum, Spread, arithmetisches Mittel und Standardabweichung zur Konstruktion für den Merkmalsvektor genutzt (maximale Dimension 45). Durch eine automatisierte Bewertung der Relevanz der einzelnen Merkmale durch den „Fisher-Score“-Algorithmus konnte die Dimension weiter reduziert werden. Darüber hinaus wurde eine statisch definierte ROI verwendet. Es wurde keine Positions Korrektur durchgeführt.

Die Tabelle beinhaltet die mit der vorher beschriebenen Konfiguration erreichten Klassifikationsraten. Zusätzlich wurde die Anzahl der verwendeten Muster pro Klasse angegeben (G=Gut- und S=Schlechtmuster). Der Flaschentyp Std 16 Snow

White zeichnete sich durch drei Klassen aus, die den Granulatanteil (Schwarz) innerhalb der Kunststoffschicht beschreiben. Die Bezeichnung Std 10 und 16 steht hierbei für die Flaschenform.

Tabelle 1: Klassifikationsergebnisse für die durch ALPLA zur Verfügung gestellten Plastikflaschen (erste Auswertung)

Flaschentyp	Verwendete Lichtkammer	Klassifikationsrate (Validierungsmenge)	Dimension
Std 10 DarkBlue	Auflicht	~88% (G=175, S=150)	28
Std 10 Blauperlmutter Apollo	Auflicht / Durchlicht	~91% (G=100, S=160)	35/15
Std 10 Blautransparent	Durchlicht	~82% (G=114, S=30)	22
Std 16 Snow White	Durchlicht	~86% (Klassen 1%, 3%, 8% mit jeweils 80)	24
Std 16 Silber	Auflicht	~97% (G=98, S=220)	18
Std 16 Hellblau-transluzent Muscle Relax	Durchlicht	~95% (G=150, S=75)	23

Des Weiteren war die Anzahl der Trainingsbeispiele für einige Flaschentypen sehr gering, was durch den enormen Aufwand bei der Herstellung und der Bewertung durch die Qualitätssicherung zu rechtfertigen ist. Um die Banddynamik zu simulieren (verwackeln, Reflexionen, Schatten) wurden einige Flaschen mehrmals aufgenommen. Der verwendete „k-Nearest-Neighbor“-Algorithmus (mit $k = 3$) nutzte den euklidischen Abstand als Distanzfunktion. Die Klassifikationsraten liegen für jeden Flaschentyp im Schnitt über 89%, wobei der schlechteste Wert bei ~82% mit dem Flaschentyp Std 16 Blautransparent erreicht wurde. Das beste Ergebnis mit ~97% wurde beim Flaschentyp Std 16 Silber ermittelt.

Tabelle 2: Klassifikationsergebnisse für die durch ALPLA zur Verfügung gestellten Plastikflaschen (zweite Auswertung)

Flaschentyp	Verwendete Lichtkammer	Klassifikationsrate (Validierungsmenge)
Std 10 DarkBlue	Auflicht	~94%
Std 10 Blauperlmutter Apollo	Auflicht / Durchlicht	100%
Std 10 Blautransparent	DurchLicht	~88%
Std 16 Snow White	DurchLicht	100%
Std 16 Silber	Auflicht	~97%
Std 16 Hellblau-transluzent Muscle Relax	DurchLicht	~94%

Für die zweite Auswertung (Tab. 2) wurde die ROI automatisch bestimmt, sowie eine Positionskorrektur (siehe Abschnitt Bildkorrektur und Bildanalyse) angewendet. Der verwendete genetische Algorithmus wurde mit einer Populationsgröße von 100 Individuen und mit 50 Generationen konfiguriert. Durch einige Experimente im Zusammenhang mit der ersten Auswertung wurde die Größe des Merkmalsvektors weiter reduziert, sodass nur auf das arithmetische Mittel im Lab-Farbraum (Dimension 3) zurückgegriffen wurde.




Abbildung 4: Clusterverteilung des Flaschentypes Std 10 Apollo nach Regionsoptimierung und Positionskorrektur




Abbildung 5: Clusterverteilung des Flaschentypes Std 10 DarkBlue nach Regionsoptimierung und Positionskorrektur

Die Ergebnisse zeigen eine deutliche Verbesserung im Gegensatz zur ersten Auswertung. Darüber hinaus konnte die Dimension drastisch reduziert werden und trägt somit zur Performance des Gesamtsystems bei. Da sich die Merkmalsvektoren im Lab-Farbraum befinden, können die ΔE -Metriken angewendet werden. Die

Flaschen mit einer unbunten Farbe (grau markierte Zeilen) wurden mit der ΔS -Metrik ausgewertet, wobei bei bunten Farben das $\Delta E76$ -Maß zur Klassifikation („k-Nearest-Neighbor“, $k = 3$) verwendet wurde. Im Vergleich zu den vorhergehenden Ergebnissen liegen die Klassifikationsraten im Schnitt über 95%, wobei eine deutliche Verbesserung bei den Flaschentypen Std 10 Blauperlmutter Apollo und Std 16 Snow White zu sehen ist.

Eine Erklärung für die guten Erkennungsraten wie zum Beispiel beim Flaschentyp Std 10 Blauperlmutter Apollo ist durch das Einlernen von Gut- und Schlechtmustern gegeben. Dabei wurden die Schlechtmuster nur in der Helligkeit variiert, wodurch eine klar trennbare Clusterverteilung entstand (siehe Abb. 4). Im Vergleich zum Flaschentyp Std 10 DarkBlue (siehe Abb. 5) liegen die entstandenen Cluster deutlich weiter voneinander entfernt und der störende Einfluss der Banddynamik ist reduziert.

Anhand der verbesserten Erkennungsraten zeigt sich erwartungsgemäß, dass die Hinzunahme der Positionskorrektur und die automatisierte ROI-Bestimmung das System stabiler gegenüber Störungen und der Banddynamik macht.

Das umgesetzte System befindet sich zurzeit im Praxistest am Standort ALPLA Berlin und wird mit den aktuellen Produktlinien eingelernt und getestet. Pro Tag werden ca. 800000 Flaschen geprüft und die Ergebnisse protokolliert. Da die Herstellung von Schlechtmustern und die Begutachtung durch die Qualitätssicherung ein aufwendiger und zeitintensiver Prozess ist, kann die Validierung des Systems nur auf Stichproben durchgeführt werden. Eine Rückmeldung durch die Firma ALPLA steht noch aus.

6 Zusammenfassung / Ausblick

In diesem Beitrag wurde die hardware- und softwaretechnische Umsetzung eines neuartigen, echtzeitfähigen, bildgestützten und prozessintegrierten Systems zur flexiblen 100%-Kontrolle von Farb-, Reflektanz- und Transluzenz-Eigenschaften in der industriellen Serienfertigung von Kunststoffflaschen vorgestellt. Das vorgestellte System wurde iterativ und unter ständiger Berücksichtigung von praktischen Problemstellungen in der Online-Farbprüfung und den Anforderungen der späteren Anwender entwickelt. Neben der Entwicklung einer Software zur 100% Online-Farbprüfung (6-10 Flaschen pro Sekunde) wurde durch die Bereitstellung einer leicht verständlichen, fast vollautomatischen Teach-Prozedur zum Einlernen der unterschiedlichen Gut- bzw. Schlechtmuster (2 Klassen) bzw. von mehreren Klassen eine wesentliche Voraussetzung für den Industrieinsatz geschaffen.

Neben der Klassifizierung von Fremdfarben, und der 2- (Gut- und Schlechtmuster) bzw. der N- Klassenklassifikation (3 und mehr unterschiedliche Farbklassen) stellte sich im praktischen Einsatz die Notwendigkeit einer 1-Klassen-Klassifikation heraus. Diese Anforderung resultiert aus der Tatsache, dass ein zeitintensives Erstellen von Schlechtmustern in der Produktionspraxis nur bei absoluter Notwendigkeit akzeptiert wird. Bei Produktionslinien mit häufigem Sorten- bzw.

Farbwechsel ist diese Aussage umso mehr zutreffend. Daher wurde für dieses Anwendungsgebiet ein Einklassenklassifikator (Support Vector Machine) entwickelt und in die bestehende Software integriert, mit dem ausschließlich Gutmuster eingelernt werden können. Unter der Voraussetzung dass innerhalb der Trainingsmenge die komplette Bandbreite von Gutmustern enthalten ist, realisiert dieser Klassifikator eine ausreichende Erkennung von Farbabweichungen gegenüber den eingelernten Gutmustern. Dieser Klassifikator kann temporär in dem Zeitraum eingesetzt werden, in dem Schlechtmuster noch nicht zur Verfügung stehen. Der Einklassenklassifikator befindet sich zurzeit in der praktischen Erprobung am Berliner ALPLA-Standort.

Ein weiterer wichtiger Gegenstand zukünftiger Arbeiten ist die Objektivierung der Farbwert-Aussagen mittels Farbabstandsberechnung und der Vergleich mit offline ermittelten Absolutfarbwerten der Musterflaschen, wie sie mit kommerziell verfügbaren, aufgesetzten Farbmessgeräten gewonnen werden können. Diesbezügliche praktische Untersuchungen sind gegenwärtig bereits angestellt.

Darüber hinaus sollen in Zukunft auch Regressionsverfahren zur Trendanalyse bzw. -vorhersage genutzt werden, um prozessbedingte Farbabweichungen noch frühzeitiger zu erkennen und ggf. zu regeln.

Danksagung

Die in diesem Beitrag vorgestellten Arbeiten werden vom BMWi im Rahmen des Programms INNO-KOM-Ost (Marktorientierte Forschung und Entwicklung) unter dem Kennzeichen MF 120079 gefördert. Die Bearbeiter bedanken sich beim Fördermittelgeber und dem Projektmanagement der Euronorm GmbH. Unser Dank gilt auch Herrn Nurna, Herrn Brunner und den beteiligten Mitarbeitern der ALPLA Werke Alwin Lehner GmbH & Co KG für die fachlich-technische sowie organisatorische Unterstützung.

Literatur

- [1] Nikitenko D., Wirth M., and Trudel K.: Applicability of White-Balancing Algorithms to Restoring Faded Colour Slides: An Empirical Evaluation. JOURNAL OF MULTIMEDIA (JMM), ISSN: 1796-2048, Volume: 3 Issue: 5, December 2008.
- [2] Marsi St., Palacios A.R., Guaneri G.: Color enhancement in a high dynamic range environment. Proceedings Image Processing: Algorithms and Systems VII, 19 January 2009, San Jose, California, USA.
- [3] Hong-Kwai Lam, Oscar C. Au, Chi-Wah Wong: Automatic white balancing using adjacent channels adjustment in RGB domain. ICME Vol.3 (2004) pp 134-139.

- [4] Hardeberg J. Y.: Acquisition and reproduction of color Images, Colormetric and Multispectral Approaches. Univeral Publishers, 2001
- [5] DIN 5033-1 (Absatz 18).
- [6] Eichler A.: Farbabstände in der industriellen Farbmessung. SunChemical, URL: www.coates.de/snd/farbabstaende.pdf, Aufruf: 04.09.2014.
- [7] Wieser M. L. S.: Vergleichende physikalische Farbmessung und sensorische Farbbeurteilung unter verschiedenen Beleuchtungssystemen an ausgewählten Brühwurstprodukten im Hinblick auf eine objektive Qualitätskontrolle in der Lebensmittelüberwachung. Dissertation Ludwig-Maximilians-Universität München (2010).
- [8] B. Jähne: Digitale Bildverarbeitung. Springer Verlag Berlin Heidelberg New York 1997, ISBN 3-540-61379-X.
- [9] Chang, C.-C.; Lin, C.-J. „LIBSVM: a library for support vector machines.“ ACM Transactions on Intelligent Systems and Technology 2:27:1—27:27, (Official implementation document), cha2011.
- [10] Gunn, S.: “Support Vector Machines for Classification and Regression”. ISIS Technical Report, 1998.
- [11] Schölkopf, B., Smola, A.J.: “Learning with Kernels: Support Vector Machines, Regularization, Optimization and Beyond.” MIT Press 2002.
- [12] Smola, A.J., Schölkopf, B.: “A Tutorial on Support Vector Regression.” NeuroCOLT2 Technical Report Series NC2-TR-1998-030, Okt 1998.
- [13] Mitchel, T.: “Machine Learning.” Mcgraw-Hill International Edit. McGraw-Hill 1997.
- [14] Witten, J.H., Eibe, F.: „Data Mining.“ Academic Press 1999.
- [15] Gu Quanquan, Li Zhenhui, Han Jiawei; „Generalized Fisher Score for Feature Selection“, URL: <http://arxiv.org/ftp/arxiv/papers/1202/1202.3725.pdf>, Aufruf: 04.09.2014.
- [16] Goldberg D. E.: Genetic Algorithms in Search, Optimization, and Machine Learning. Addison-Wesley, 1989, ISBN 0-201-15767-5.
- [17] Mitchell M.: An Introduction to Genetic Algorithms. MIT Press, Cambridge, MA 1996.