

Methoden zur optischen Qualitätskontrolle

Anwendung in der Produktion von Xenon-Lampen

Diplomarbeit

Fabian Timm



Institut für Neuro- und Bioinformatik
Universität zu Lübeck

Ausgegeben von
Prof. Dr. rer. nat. Thomas Martinetz

Betreut durch
PD Dr. Ing. Erhardt Barth

In Kooperation mit

Dr. rer. nat. Christian Arlt
Philips GmbH, Aachen
Innovation/Vision E-Team

Dipl. Ing. Michael Clausohm
Clausohm Software GmbH, Neverin

November 2006

Zusammenfassung

Automatische Qualitätskontrolle in industriellen Anwendungen, die bisher nur von Menschen realisierbar waren, bekommt eine immer größere Bedeutung. Durch eine Automatisierung wird es möglich, zuverlässiger, schneller und effizienter zu produzieren. Einen großen Stellenwert in der Forschung hat die optische Qualitätskontrolle, da sie direkt mit der Leistungsfähigkeit des menschlichen Sehens verglichen wird und somit enorme Anforderungen erfüllen muss.

In dieser Arbeit werden Methoden zur optischen Qualitätskontrolle von Xenon-Lampen evaluiert. Die automatische Einteilung der Lampen erfolgt durch eine Analyse der Schweißnähte. Dazu werden spezielle Verfahren zur Extraktion von Merkmalen sowie deren Klassifikation verwendet. Anhand von Grauwertbildern werden einfache, formgebende Merkmale sowie Statistiken erster Ordnung und statistische geometrische Merkmale berechnet, die anschließend mit verschiedenen Klassifikationsverfahren wie beispielsweise Support-Vector-Machine oder k-Nearest-Neighbor eingeteilt werden.

Die besten Ergebnisse bei der Klassifikation von geschweißten und ungeschweißten Xenon-Lampen liefert die Support-Vector-Machine in Kombination mit formgebenden Merkmalen und einer Fehlerrate von 0.0042 %. Bei der Klassifikation von gut und schlecht geschweißten Xenon-Lampen durch die Berechnung von statistischen, geometrischen Merkmalen erreicht die Support-Vector-Machine mit 6.25 % ebenfalls die niedrigste Fehlerrate.

Danksagung

*Wenn ich mein Leben noch einmal leben könnte,
würde ich mehr Fehler machen.
Ich würde bis zum Äußersten gehen.
Ich würde alberner und verrückter sein
und würde mehr Chancen wahrnehmen.
Ich würde mehr unternehmen,
würde mehr Berge besteigen,
in mehr Flüssen schwimmen
und mehr Sonnenuntergänge beobachten.*

Nadine Stair (im Alter von 85 Jahren)

An dieser Stelle möchte den Menschen danken, die mich während der Arbeit mit ihrer Hilfe unterstützt haben. Der erste Dank gilt Herrn Clausohm sowie Herrn Arlt, die mir überhaupt erst ermöglicht haben, diese Arbeit durchzuführen und mich während der ganzen Zeit mit Bildern versorgt haben.

Ein weiterer Dank gilt Herrn Barth für die Betreuung dieser Arbeit. Die eigenen Ideen mit Menschen zu besprechen, die eine kritische Beurteilung geben, ist der Grundstein für die Entwicklung eigener Methoden. Weiterhin möchte ich mich bei Kai Labusch bedanken, der für mich stets ein offenes Ohr hatte und meine Überlegungen und Fragen aus allen Themengebieten mit mir besprochen hat. Bei Alexandru Condurache bedanke ich mich für die kritische Betrachtung der angewendeten Methoden aus dem Bereich Bildverarbeitung. Martin Haker möchte ich für das zahlreiche Korrekturlesen danken. Eine Person, die sich die genauen Zusammenhänge durchliest und auch kritisch genug beurteilt, ist von großer Bedeutung für die Erstellung einer solchen Arbeit. Hanna danke ich ebenfalls für das Korrekturlesen und die zahlreichen Hinweise in neuer und alter Rechtschreibung.

Der größte Dank gilt meiner Familie, die mich während des gesamten Lebens in allen Dingen unterstützt hat und mir ein großes Vertrauen schenkt.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Die Xenon-Lampe	5
1.2	Problemstellung und Anforderungsanalyse	8
1.3	Zielsetzung	9
1.4	Gliederung	10
2	Qualitätskontrolle von Schweißnähten	15
2.1	Aufbau des Bildverarbeitungssystems	16
2.2	Allgemeine Vorgehensweise	18
2.3	Formalisierung der visuellen Inspektion von Schweißnähten	22
2.3.1	Der Schweißprozess im Detail – Stufeneinteilung	22
2.3.2	Beleuchtungsmodell und relevante Bildinformationen	27
2.3.3	Relevante Bildinformationen (1. Stufe)	29
2.3.4	Die Fehlertypen von geschweißten Polen (2. Stufe)	31
2.3.5	Die Beurteilung der Mitarbeiter	34
2.4	Datenlage	35
3	Extraktion der Region-Of-Interest	39
3.1	Beschreibung der Region-Of-Interest	40
3.2	Segmentierung der Region-Of-Interest	41
3.2.1	Template Matching zur Bestimmung der t-ROI	42
3.2.2	Binarisierung durch Schwellwerte	46
3.2.3	Extraktion der Konturpunkte	50
3.2.4	Kreisdetektion	51
4	Merkmalsextraktion und -selektion	63
4.1	Individuelle Merkmale der 1. Stufe	63
4.1.1	Sichtbare Ringfläche	63
4.1.2	Regularität (Strahlenalgorithmus)	64
4.2	Individuelle Merkmale der 2. Stufe	65
4.2.1	Statistische Geometrische Merkmale (SGF)	69
4.3	Principle-Component-Analysis (PCA)	78

4.4	Merkmalsselektion	82
4.4.1	Merkmalsselektion durch FSCORE	82
4.4.2	Gewichtsvektor der trennenden Hyperebene	83
5	Klassifikation	85
5.1	k-Nearest-Neighbor (kNN)	85
5.2	Prototyp-Klassifikator (Prot)	87
5.3	Support-Vector-Machine (SVM)	88
5.3.1	Linearer Fall	88
5.3.2	Nichtlinearer Fall	91
5.4	Statistische Lerntheorie	92
5.4.1	Generalisierungsfehler	93
5.4.2	VC-Dimension	93
5.4.3	Bias-Variance-Dilemma	95
5.5	Validierungsmethoden	96
5.5.1	Externe Validierung	97
5.5.2	Interne Validierung	98
5.5.3	Receiver-Operator-Characteristic (ROC)	101
6	Ergebnisse und Diskussion	103
6.1	Resultate der 1. Stufe	103
6.1.1	Merkmalsevaluation	103
6.1.2	Vergleich der Klassifikatoren	104
6.2	Resultate der 2. Stufe	107
6.2.1	Principle-Component-Analysis	108
6.2.2	Merkmalsevaluation	110
6.2.3	Support-Vector-Machine	113
6.2.4	k-Nearest-Neighbor	119
6.2.5	Prototyp-Klassifikator	119
6.2.6	Vergleich der Klassifikatoren	120
7	Zusammenfassung und Ausblick	123
	Literaturverzeichnis	129
A	Laserschweißen	135

1 Einleitung

2006 ist das Jahr der Informatik.

Neue Technologien und Ideen beeinflussen das alltägliche Leben mehr denn je. Während Computer und Handy bereits Einzug in den Alltag gefunden haben, nimmt der Einfluß der Informatik auf weitere Bereiche des Lebens in stetigem Maße zu. So können die Bürger Estlands beispielsweise ihr Parlament bereits elektronisch wählen, und in Korea ist der Cyberspace ein zweiter Lebensraum geworden. In Japan gibt es Roboter, die Menschen und Tieren nachempfunden sind und in der Altenpflege sowie Kinderbetreuung eingesetzt werden. Der südafrikanische Wissenschaftler Louis Liebenberg entwickelt seit fünf Jahren ein „CyberTracker-System“, das für den Tier- und Umweltschutz im südlichen Afrika eingesetzt werden soll. Das System basiert auf altem, überliefertem Wissen von Ureinwohnern in Botswana. Diese Menschen beherrschen die Kunst des Spurenlesens wie niemand sonst und können allein anhand einer Spur Alter, Geschlecht und Verfassung eines Tieres bestimmen. Dabei verwenden sie zu großen Teilen visuelle Informationen, und so soll auch der „CyberTracker“ diese Aufgabe durch die Analyse von digitalen Kamerabildern lösen.

Maschinelles Sehen (engl. *Computer Vision*) ist ein Teil der Informatik, der sich mit der computergestützten Lösung von visuellen Aufgabenstellungen beschäftigt. Häufig wird versucht, die menschlichen Fähigkeiten, die zur Lösung des Problems führen, zu simulieren. Dies stellt eine große Herausforderung dar, die keinesfalls immer bewältigt werden kann. Betrachtet man den Aufbau des menschlichen Auges, so zeichnet sich bereits eine gewisse Komplexität des Problems ab. Um beispielsweise computergestützt Texturen mit maschinellem Sehen zu klassifizieren, muss man sich zunächst fragen, wie das menschliche Auge Texturen erkennen und unterscheiden kann. Gerade bei komplizierteren visuellen Aufgaben können die Menschen meist nur schwer erklären, warum und wie sie etwas unterscheiden. Daher ist es umso wichtiger zu verstehen, was genau im Menschen bei solch einem Vorgang abläuft. Die Beschreibung der Abläufe im visuellen Kortex des Menschen sowie deren Simulation stellt ein aktuelles Forschungsgebiet der Wissenschaft dar.

Prinzipiell gibt es zwei Ansätze, um eine visuelle Aufgabenstellung mit maschinellem Sehen zu lösen - einen mit und einen ohne a-priori-Wissen. Dabei bezieht sich

der Begriff a-priori-Wissen zum Beispiel auf eine genaue Spezifikation der Lösungsstrategie eines Menschen. Falls ein solches Wissen vorhanden ist, muss es möglichst genau formalisiert werden, um es zur Entwicklung spezifischer Methoden nutzen zu können. Kann man auf solch ein Vorwissen nicht zurückgreifen, wendet man zunächst klassische Verfahren der Datenanalyse an. Häufig werden auch Verfahren aus anderen Gebieten herangezogen, um bessere Lösungen zu finden. Das maschinelle Sehen ist daher kein klar abgegrenztes Gebiet. Es gibt viele unterschiedliche Themenbereiche, die im maschinellen Sehen Anwendungen finden. So werden zum Beispiel auch Inhalte aus den Bereichen künstliche Intelligenz, Mustererkennung, Signal- und Bildverarbeitung, maschinelles Lernen sowie Neuro- und Bioinformatik verwendet. Abbildung (1.1) gibt eine beispielhafte Übersicht einiger Themengebiete, die mit maschinellem Sehen verbunden sind.

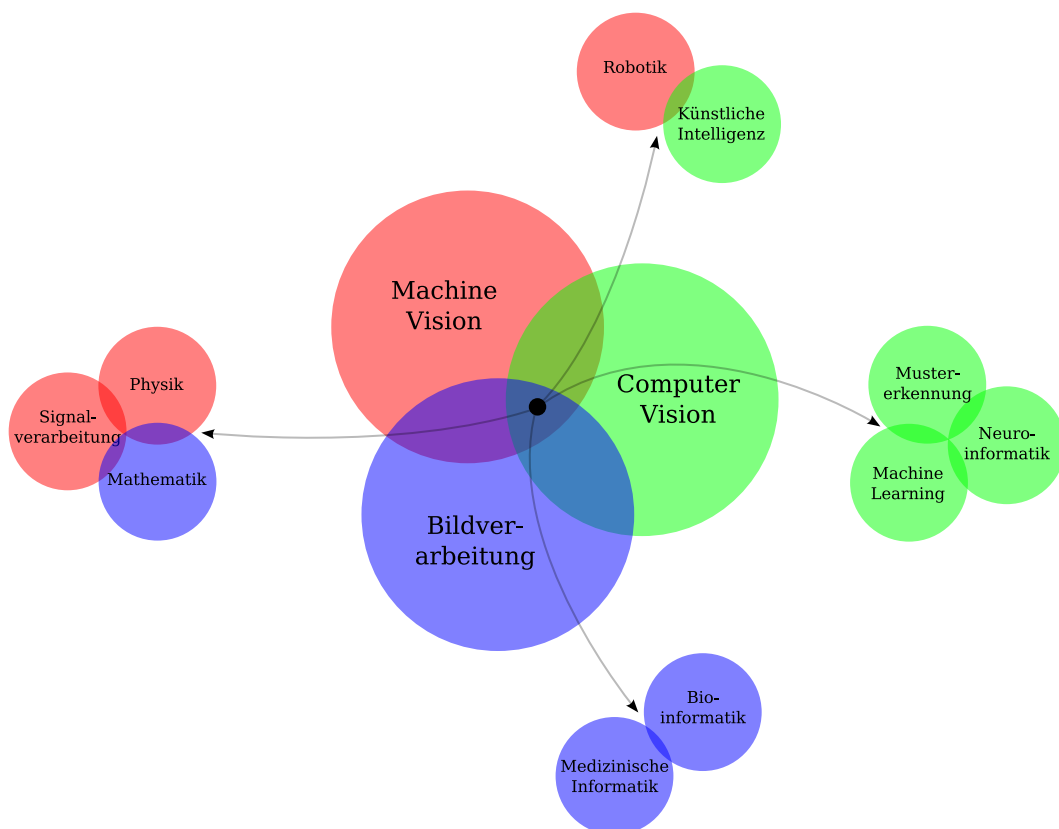


Abbildung 1.1: Maschinelles Sehen und ein Auszug verwandter Themengebiete in der Übersicht. Dabei steht der Begriff *Machine Vision* für maschinelles Sehen im industriellen Einsatz.

Bei industriellen Aufgabenstellungen kann meist sehr genau spezifiziert werden, um welche visuellen Merkmale es sich handelt. Dies bietet den Vorteil, dass individuelle und sehr leistungsfähige Ansätze entwickelt werden können, die den allgemeinen Verfahren (z.B. Statistiken, Frequenzanalyse,...) überlegen sind. Ein wichtiger Bestandteil dieser Arbeit stellt daher die exakte Formalisierung der visuellen Inspektion durch den Menschen dar.

Trotz der erwähnten Schwierigkeiten bietet das maschinelle Sehen viele Methoden, die zu sehr guten Ergebnissen eines visuellen Problems führen. Auch wenn das Ziel, die Präzision eines Menschen zu erreichen oder gar zu übertreffen, in vielen Fällen bis heute unerreicht geblieben ist, bietet das maschinelle Sehen im industriellen Einsatz eine Reihe von Vorteilen gegenüber einer Beurteilung durch Menschen. Während der Mensch beeinflusst wird von äußeren und inneren Faktoren wie etwa Hitze, Lärm, mangelnde Leistungsbereitschaft oder Konzentrationsschwäche, arbeitet ein System mit maschinellem Sehen davon unabhängig und oft effizienter. Über einen langen Zeitraum gesehen ist ein solches System damit auch leistungsfähiger als ein Mensch.

Aus diesem Grund setzt man in vielen verschiedenen Bereichen maschinelles Sehen zur Lösung eines visuellen Problems ein. So werden Verfahren in der Verkehrstechnik zur Entwicklung von modernen Radarfallen, in der Sicherheitstechnik bei der Zugangskontrolle oder der Gesichtererkennung [GWBS06] sowie auch der Schrifterkennung verwendet [Lab04, Mat05, LMB]. Ein weiteres innovatives Gebiet ist die Medizintechnik, in der maschinelles Sehen zur Diagnoseunterstützung verwendet wird [Tim05]. Einen stetig wachsenden Bereich stellen industrielle Anwendungen zur Produktautomatisierung und Qualitätssicherung dar.

Jede Problemstellung hat andere Anforderungen und Bedingungen und sollte deshalb durch individuelle Verfahren gelöst werden. Es existieren keine generalisierten Methoden, um ein Problem durch maschinelles Sehen zu lösen, und nur selten können Verfahren zur Lösung eines Problems auch auf ein anderes übertragen werden.

Diese Arbeit beschäftigt sich mit der Entwicklung von speziellen Methoden zur optischen Qualitätskontrolle von Xenon-Lampen. Die Lampen befinden sich in einem bestimmten Produktionsschritt, an dem zwei Schweißnähte überprüft werden müssen. Dazu wird im ersten Schritt untersucht, ob diese Stellen geschweißt wurden, während im zweiten Schritt die Güte der Schweißung ermittelt wird. Bisher wurden die Lampen visuell von einem Mitarbeiter inspiziert und klassifiziert. Um eine

bessere Effizienz zu erreichen, soll dieser Schritt automatisiert werden. Die nächsten Abschnitte beschreiben daher die Xenon-Lampe, deren Aufbau und Funktionsweise, die Problemstellung sowie die Zielsetzung dieser Arbeit. Anschließend folgt eine Gliederung dieser Arbeit.

7 Zusammenfassung und Ausblick

Im ersten Teil dieses abschließenden Kapitels werden die verwendeten Methoden aus den vorangegangenen Kapiteln zusammengefasst. Dabei wird analog zur Gliederung dieser Arbeit mit den Verfahren zur Extraktion der ROI begonnen. Anschließend werden die Ansätze zur Merkmalsberechnung sowie die Klassifikationsverfahren erwähnt.

Im zweiten Abschnitt werden die selbst entwickelten Methoden erläutert. Für diese Arbeit wurden in jedem der drei Bereiche (Extraktion der ROI, Merkmalsberechnung, Klassifikation) eigene Ideen konzipiert.

Im dritten Teil des Kapitels werden die Ergebnisse kurz beschrieben und Verbesserungsmöglichkeiten dargestellt.

Der letzte Abschnitt gibt einen Überblick über weitere Ansätze zu den verschiedenen Bereichen (Extraktion der ROI, Klassifikation, Parameterselektion) und stellt andere Anwendungsgebiete der in dieser Arbeit verwendeten Methoden dar.

Verwendete Methoden

Extraktion der ROI Die Extraktion der Region-Of-Interest wurde in dieser Arbeit in zwei Schritten durchgeführt, um eine möglichst präzise Bestimmung und Extraktion der relevanten Regionen zu erreichen. Dazu wurden die spezifizierten Bildregionen (kreisrunder linker und rechter Pol) zunächst durch Template-Matching grob bestimmt. Die detektierten Regionen können sehr zuverlässig ermittelt werden und bilden die so genannte *transfer*-ROI (t-ROI). Anhand dieser Bildausschnitte werden durch Binarisierung, morphologische Operatoren und Kantendetektion Konturpunkte bestimmt, die als Eingabe für eine Kreisdetektion dienen. Durch die Hough-Transformation wird jeweils der Kreis in der t-ROI bestimmt, den die Konturpunkte am besten beschreiben. Der auf diese Weise detektierte Kreis stellt den gefundenen Pol dar, wird aus t-ROI extrahiert und bildet die Grundlage der Methoden zur Merkmalsberechnung.

Merkmalsberechnung Zur Berechnung von Merkmalen wurde die Problemstellung in zwei Klassifikationsstufen eingeteilt. Die erste Stufe beschäftigt sich mit der Unterscheidung von geschweißten und ungeschweißten Pole, wohingegen die zweite die Qualität von geschweißten Polen bestimmt.

In Abhängigkeit von der jeweiligen Klassifikationsstufe wurden verschiedene Verfahren zur Berechnung von Merkmalen gewählt. Für die erste Stufe wird die sichtbare Ringfläche der Polöffnung sowie die Regularität der Öffnung ermittelt. Zusätzlich werden Statistiken erster Ordnung (Mittelwert, Median, Varianz, Entropie) für die Bilder der Pole berechnet.

Zur Qualitätsprüfung der Schweißnähte (zweite Stufe) wurden statistische geometrische Merkmale eingesetzt, die eine Berechnung der Eigenschaften von hellen und dunklen Komponenten (Regionen) im Bild ermöglichen.

Klassifikation Als Grundlage der Klassifikation wurden die beschriebenen Methoden der Merkmalsberechnung eingesetzt, um für jedes Bild einen Merkmalsvektor zu erhalten, der für die verschiedenen Klassifikationsmethoden als Eingabe dient. Neben dem k-Nearest-Neighbor (kNN), einem sehr simplen und beliebten Ansatz, wurde die Support-Vector-Machine (SVM) verwendet. Die SVM ist ein neues und mathematisch sehr fundiertes Verfahren, das in vielen Anwendungen zu sehr guten Ergebnissen geführt hat. Als Vergleich zur Klassifikation der individuellen Merkmale wurde eine Klassifikation der Rohdaten (Bilder) durch die SVM und einen Prototyp-Klassifikator durchgeführt. Dazu wurden die Bilder auf eine kleinere Größe skaliert, entauscht und als Zeilenvektor dargestellt. Anhand dieser Daten wurden mittels *Neural-Gas* für jede Klasse Prototypen erstellt. Einer neuer Datenpunkt erhält die Klassenzugehörigkeit des dichtesten Prototypen (euklidischer Abstand).

Eigene Ideen

Extraktion der ROI – Kreisdetektion Zur Bestimmung der ROI wird in dieser Arbeit eine Kreisdetektion anhand von Konturpunkten benötigt. Neben der Hough-Transformation wurde ein eigener, iterativer Ansatz entwickelt, der mittels einer gegebenen Punktmenge einen Kreis „lernt“. Dabei wird ausgehend von dem aktuellen Kreismittelpunkt der am weitesten entfernte Punkt \vec{x} bestimmt, der sich innerhalb einer δ -Umgebung um den aktuellen Kreis befindet. Der neue Kreismittelpunkt wird

mit einer Lernschrittweite ε in Richtung \vec{x} verschoben. Als neuer Radius wird der Median aller Distanzen zum Mittelpunkt verwendet. Die Lernrate ε und die Umgebung δ werden mit jedem Schritt erniedrigt bis ein spezifiziertes Abbruchkriterium erreicht ist.

Merkmalsberechnung – Strahlenalgorithmus und Erweiterung der SGF Zur Klassifikation von geschweißten und ungeschweißten Polen wurde ein Strahlenalgorithmus für die Erfassung der Regularität der Polöffnung entwickelt. Dabei werden ausgehend vom Bildzentrum Grauwertverläufe entlang verschiedener Richtungen bestimmt. Für jeden Strahl wird auf dem Gradienten des Grauwertverlaufs der minimale Wert und dessen Position ermittelt. Statistiken erster Ordnung fassen die beiden Merkmale über alle Strahlen zusammen. Auf diese Weise kann die Regularität des Pols in alle Richtungen bestimmt werden. Ungeschweißte Pole, die gleiche Eigenschaften in alle Richtungen aufweisen, können dadurch von geschweißten unterschieden werden, die deutliche Unregelmäßigkeiten aufweisen.

Zur Anpassung in die zweite Klassifikationsstufe (gut/schlecht geschweißt) wurde die ursprünglichen statistischen geometrischen Merkmale erweitert. Dazu werden 572 Merkmale pro Bild berechnet, die spezielle Eigenschaften von Komponenten (zusammenhängenden Regionen) wie beispielsweise die Form, Ausdehnung, Position und Entfernung zum Bildzentrum statistisch erfassen. Diese Vielzahl von Merkmalen wurde gewählt, um auch Fehlertypen beschreiben zu können, die zwar bekannt sind, aber für die keine Bilder vorhanden waren. Eine Selektion von Merkmalen kann mit den in Kapitel 4.4 beschriebenen Verfahren erreicht werden.

Klassifikation – Parameterselektion Die verschiedenen Klassifikationsmethoden besitzen diverse Parameter, die über Validierungsverfahren bestimmt werden. Dazu wird bei einer Validierung der Generalisierungsfehler (GF) geschätzt und die Parameterkombination gewählt, die den kleinsten GF liefert. Für diese Arbeit wurde ein neues Vorgehen entwickelt, bei dem die Modelle (Parameterkombination) gemäß ihrer Komplexität sortiert werden. Als bestes Modell wird dasjenige bestimmt, das der besten Kompromiß aus niedrigen GF, niedriger Komplexität und einer „stabilen“ Umgebung liefert. Somit wird das einfachste Modell gewählt, das eine geringe Varianz bei Änderung der Parameter und der Daten ergibt.

Ergebnisse

Die automatisierte Klassifikation von ungeschweißten und geschweißten Xenon-Lampen anhand von Lichtreflektionen kann mit der Support-Vector-Machine und einer geschätzten Fehlerrate von 0 % für den linken Pol und von 0.0042 % für den rechten Pol erfolgen. Die dabei entscheidenden Merkmale sind die sichtbare Ringfläche der Polöffnung und die Regelmäßigkeit dieser Öffnung. Damit wird das Vorgehen der Mitarbeiter zur manuellen Inspektion widerspiegelt. Die sehr niedrigen Fehlerraten zeigen, dass eine effiziente und sehr leistungsfähige Automatisierung der manuellen Inspektion mit den erwähnten Methoden erreicht werden kann.

Bei der automatischen Beurteilung der Qualität der Schweißung und deren Einteilung in gut und schlecht geschweißte Xenon-Lampen sind die Form, Größe und Position heller Objekte von Bedeutung. Auch hier ist ein Bezug zur manuellen Inspektion zu erkennen. Beim linken Pol wird durch die Kombination von Support-Vector-Machine und statistischen, geometrischen Merkmalen eine geschätzte Fehlerate von 0.38 % erzielt, wohingegen diese beim rechten Pol 6.25 % beträgt. Es ist zu erwarten, dass das Ergebnis für den rechten Pol noch deutlich verbessert werden kann, indem die Klassenzugehörigkeit der Xenon-Lampen während des Produktionsprozesses zuverlässig aufgezeichnet und nicht nachträglich allein anhand der Bilder bestimmt wird. Durch eine größere Datenmenge können die bisherigen Ergebnisse zusätzlich verbessert werden, da für einige Fehlertypen keine oder nur sehr wenige Bilder vorhanden waren und daher die entwickelten Methoden für diese Typen keine Aussage zulassen. Zudem waren die Hälfte der Bilder aufgrund technischer Probleme sehr stark verrauscht, sodass die Fehlerrate bei einer Reduzierung des Rauschen deutlich reduziert werden kann.

Ausblick

Vorwissen Ein Ziel beim Einsatz von Methoden des überwachten Lernens ist es, das Vorwissen optimal zu nutzen und die Daten dadurch gut zu klassifizieren. Je mehr von diesem Wissen genutzt werden kann, umso besser können die Systeme lernen. Eine gute Möglichkeit, das lernende System aufzubauen, besteht darin, den Mitarbeiter in den Lernprozess zu integrieren. Durch diese Interaktion kann nicht nur das System die Lösung des Problems „online“ lernen, sondern auch der Mitarbeiter

kann später bei schwierigen Entscheidungen den Vorschlag des Systems betrachten. Sobald das System zuverlässige Entscheidungen trifft, muss der Mitarbeiter diese nur stichprobenartig überprüfen und gegebenenfalls eingreifen. Ein weiterer Schritt wäre die Verwendung eines „Bonus-Systems“, bei dem das lernende System einen positiven Bonus vom Menschen für sehr gute Entscheidungen erhält und einen negativen, falls die Entscheidung sehr schlecht war.

Extraktion der ROI – Kreisdetektion Im ersten Teil der Arbeit wurde ein neuer Ansatz zur Detektion von Kreisen vorgestellt. Die Robustheit des Verfahrens ist dabei noch ungenügend, könnte aber in Verbindung mit *aktiven* Konturen [MT00] deutliche Verbesserungen bringen. Es müsste überprüft werden, ob eine solche Kombination die Leistung der Hough-Transformation übertreffen kann.

Methoden zur Klassifikation Auf dem Gebiet der Klassifikation gibt es seit einigen Jahren einen neuen Ansatz, die Relevance-Vector-Machine (RVM) [Tip99], die dieselben Vorteile wie die Support-Vector-Machine besitzt, dafür aber keine aufwändige Parametervalidierung mehr benötigt. Des Weiteren ist die Anzahl der „relevanten“ Datenpunkte zur Klassifikation deutlich niedriger als bei der SVM bei annähernd gleicher Leistung. Es wäre interessant zu untersuchen, ob die RVM gegenüber der SVM bei der vorliegenden Problemstellung deutliche Verbesserungen liefern kann.

Parameterselektion Die Suche nach optimalen Parametern und dem optimalen Modell bei einer gegebenen Aufgabenstellung stellt ein ungelöstes Problem dar. Zwar gibt es eine Reihe von verschiedenen Validierungstechniken, aber für alle wird ein enormer Rechenaufwand benötigt, und häufig liefern diese Methoden unterschiedliche Ergebnisse. Wie in dieser Arbeit angewendet, sollte man nicht nach *den* optimalen Parametern suchen, sondern vielmehr eine „stabile“ Parameterregion eines Klassifikators mit geringer Komplexität finden, bei dem kleine Änderungen der Parameter nur zu kleinen Varianzen in den Ergebnissen führen. Es bleibt offen, ob dieser neu entwickelte Ansatz eine entscheidende Verbesserung zu den etablierten Validierungsmethoden darstellt.

Eine neue Methode zur Wahl der Parameter eines Klassifikators mit Kernfunktion ist die so genannte *Kernel Polarization* [Bar05]. Dabei wird mithilfe der Kernfunktion

eine Zielfunktion aufgestellt, die hinsichtlich aller Parameter maximiert werden soll und im Maximum die optimalen Parameter liefert. Zu überprüfen bleibt, ob diese Methode zu gleichen Resultaten wie der Parameterselektion durch eine Validierung führen kann.

Weitere Anwendungsgebiete Die Verwendung von statistischen, geometrischen Merkmalen in ihrer ursprünglichen Form hat bereits zu guten Ergebnissen in der Praxis geführt [Tim05]. Die in dieser Arbeit weiterentwickelte Methode kann überall dort eingesetzt werden, wo feine Strukturen in ihrer Form und Zusammensetzung entscheidende Merkmale darstellen. Es wäre interessant zu überprüfen, ob dieser Ansatz beispielsweise auch bei der automatischen Oberflächeninspektion oder ähnlichen Problemstellungen zu guten Resultaten führt. Ein weiteres Anwendungsgebiet der statistischen, geometrischen Merkmale könnte die Erkennung von Zellen in verschiedenen Mitose-Stadien anhand von Immunfluoreszenzbildern darstellen. Dabei könnten beispielsweise Zellen in der Metaphase dadurch erkannt werden, dass sich deutlich fluoreszierende, runde Regionen (Spindelfaserapparate) entfernt vom Zentrum befinden, wohingegen stark fluoreszierende, längliche Komponenten (Chromosomen) in der Äquatorialebene – also in der Mitte zwischen den Spindelpolen – angeordnet sind.

Literaturverzeichnis

- [Bar05] BARAM, Y.: Learning by Kernel Polarization. In: *Neural Computation* 17 (2005), Nr. 6, S. 1264–1275
- [BP93] BRUNELLI, R. ; POGGIO, T.: Face Recognition: Features versus Templates. In: *IEEE Trans. Pattern Analysis and Machine Intelligence* 15 (1993), Nr. 10, S. 1042–1052
- [BSMM01] BRONSTEIN, I. N. ; SEMENDÂEV, K. A. ; MUSIOL, G. ; MÜHLIG, H.: *Taschenbuch der Mathematik, 5. Auflage*. Frankfurt am Main : Verlag Harri Deutsch, 2001
- [CAC04] COLE, L. ; AUSTIN, D. ; COLE, L.: Visual Object Recognition Template Matching. In: *Australasian Conference on Robotics and Automation*. Canberra, Australia, Dezember 2004
- [Can86] CANNY, J.: A Computational Approach To Edge Detection. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 8 (1986), November, Nr. 6, S. 679–698
- [CL03] CHEN, Y. ; LIN, C.: Combining SVMs with Various Feature Selection Strategies. In: *NIPS workshop on feature extraction and feature selection* (2003)
- [CNT95] CHEN, Y. Q. ; NIXON, M. S. ; THOMAS, D. W.: Statistical Geometrical Features For Texture Classification. In: *Pattern Recognition* 28 (1995), Nr. 4, S. 537–552
- [CST00] CRISTIANINI, N. ; SHAWE-TAYLOR, J.: *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. Cambridge, U.K. : Cambridge University Press, 2000
- [CV95] CORTES, C. ; VAPNIK, V.: Support-vector networks. In: *Machine Learning* 20 (1995), Nr. 3, S. 273–297

- [DH72] DUDA, R. O. ; HART, P. E.: Use of the Hough transformation to detect lines and curves in pictures. In: *Commun. ACM* 15 (1972), Nr. 1, S. 11–15
- [DSAW02] DEMANT, C. ; STREICHER-ABEL, B. ; WASZKEWITZ, P.: *Industrielle Bildverarbeitung, 2. Auflage*. Springer, 2002
- [Fuk90] FUKUNAGA, K.: *Statistical Pattern Recognition*. 2nd. San Diego : Academic Press, 1990 – 443–446 S
- [GSB03] GRAF, A. B. A. ; SMOLA, A. J. ; BORER, S.: Classification in a normalized feature space using support vector machines. In: *IEEE Transaction on Neural Networks* 14 (2003), S. 597–605
- [GW92] GONZALEZ, R. C. ; WOODS, R. E.: *Digital Image Processing*. 3rd. Addison-Wesley, 1992
- [GWBS06] GRAF, A. ; WICHMANN, F. ; BÜLTHOFF, H. ; SCHÖLKOPF, B.: Classification of Faces in Man and Machine. In: *Neural Comput.* 18 (2006), Nr. 1, S. 143–165
- [Hay99] HAYKIN, S.: *Neural Networks: A Comprehensive Introduction*. Prentice Hall, 1999
- [HKO01] HYVÄRINEN, A. ; KARHUNEN, J. ; OJA, E.: *Independent component analysis*. John Wiley & Sons, 2001
- [Hou62] HOUGH, P. V. C.: *Method and means for recognizing complex patterns*. 1962 – U.S. Patent 3069654
- [HTF01] HASTIE, T. ; TIBSHIRANI, R. ; FRIEDMAN, J. H.: *The Elements of Statistical Learning*. Springer, Juli 2001
- [JMNS95] JÄHNE, B. ; MASSEN, R. ; NICKOLAY, B. ; SCHARFENBERG, H.: *Technische Bildverarbeitung-Maschinelles Sehen*. Berlin, Heidelberg : Springer-Verlag, 1995
- [Koh95] KOHAVI, R.: A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. In: *Proceedings of the Fourteenth*

- International Joint Conference on Artificial Intelligence*. San Mateo : Morgan Kaufmann, August 1995, S. 1137–1145
- [Lab04] LABUSCH, K.: *MaxMinOver: Ein neues iteratives Verfahren zur Support-Vektor-Klassifikation mit Anwendung in der Gesichtererkennung*, Diplomarbeit, Universität zu Lübeck, Institut für Neuro- und Bioinformatik, Diplomarbeit, 2004
- [Lew95] LEWIS, J.: Fast normalized cross-correlation. In: *Vision Interface (1995)*
- [LMB] LABUSCH, K. ; MARTINETZ, T. ; BARTH, E.: Learning optimal features for visual pattern recognition. – zur Veröffentlichung eingereicht
- [Mat05] MATTERN, J. P.: *Unterschriftsverifikation basierend auf temporalen Sequenzen lokal extrahierter Merkmale*, Bachelorarbeit, Universität zu Lübeck, Institut für Neuro- und Bioinformatik, Bachelorarbeit, 2005
- [MBS93] MARTINETZ, T. ; BERKOVICH, S. ; SCHULTEN, K.: 'Neural-Gas' Network for Vector Quantization and its Application to Time-Series Prediction. In: *IEEE Trans. on Neural Networks* 4 (1993), Nr. 4, S. 558–569
- [MLS] MARTINETZ, T. ; LABUSCH, K. ; SCHNEEGASS, D.: SoftDoubleMax-MinOver for Simple Incremental Support-Vector-Classification. – in Vorbereitung
- [MLS05] MARTINETZ, T. ; LABUSCH, K. ; SCHNEEGASS, D.: SoftDoubleMinOver: A Simple Procedure for Maximum Margin Classification. In: DUCH, Wlodzislaw (Hrsg.) ; KACPRZYK, Janusz (Hrsg.) ; OJA, Erkki (Hrsg.) ; ZADROZNY, Slawomir (Hrsg.): *Artificial Neural Networks: Biological Inspirations. ICANN 2005: 15th International Conference. Proceedings, Part II*, 2005, S. 301–306
- [MS91] MARTINETZ, T. ; SCHULTEN, K.: A Neural-Gas Network Learns Topologies. In: KOHONEN, T. (Hrsg.) ; MÄKISARA, K. (Hrsg.) ; SIMULA, O. (Hrsg.) ; KANGAS, J. (Hrsg.): *Proc. International Conference on Artificial Neural Networks* (Espoo, Finland) Bd. I. Amsterdam, Netherlands : North-Holland, 1991, S. 397–402

- [MT00] MCINERNEY, T. ; TERZOPOULOS, D.: T-Snakes: Topology Adaptive Snakes. In: *Medical Image Analysis* 4 (2000), S. 73–91
- [Ots79] OTSU, N.: A threshold selection method from gray level histograms. In: *IEEE Trans. Systems, Man and Cybernetics* 9 (1979), S. 62–66
- [Oza78] OZAWA, K.: Classification of the Keyhole Shaped Tombs by Template Matching Method. In: *IEEE Trans. Computers* 27 (1978), Nr. 5, S. 462–467
- [Pea01] PEARSON, K.: On lines and planes of closest fit to systems of points in space. In: *The London, Edinburgh and Dublin Philosophical Magazine and Journal of Science* 2 (1901), S. 559–572
- [Ree72] REED, S. K.: Pattern Recognition and Categorization. In: *Cognitive Psychology* 3 (1972), S. 392–407
- [Rus99] RUSS, J. C.: *The Image Processing Handbook (3rd ed.)*. Boca Raton, FL, USA : CRC Press, Inc., 1999
- [Tim05] TIMM, F.: *Texturbasierte Klassifikation von Autoimmunreaktionen anhand von Immunfluoreszenzbildern, Studienarbeit*, Universität zu Lübeck, Institut für Neuro- und Bioinformatik, Studienarbeit, 2005
- [Tip99] TIPPING, M. E.: The Relevance Vector Machine. In: SOLLA, Sara A. (Hrsg.) ; LEEN, Todd K. (Hrsg.) ; MÜLLER, Klaus-Robert (Hrsg.): *NIPS*, The MIT Press, 1999, S. 652–658
- [TL03] TSAI, D. M. ; LIN, C. T.: Fast normalized cross correlation for defect detection. In: *Pattern Recognition Letters* 24 (2003), Nov, Nr. 15, S. 2625–2631
- [Tö05] TÖNNIES, K. D.: *Grundlagen der Bildverarbeitung*. Pearson München, 2005 – ISBN 3–8273–7155–4
- [Vap97] VAPNIK, V.: The Support Vector Method. In: *ICANN* Bd. 1327, Springer, 1997, S. 263–271
- [Vap00] VAPNIK, N. V.: *The Nature of Statistical Learning Theory*. Springer-Verlag, New York., 2000

-
- [VDI89] VDI/VDE, Richtlinie: Automatisierte Sichtprüfung, Beschreibung der Prüfaufgabe. (1989), Nr. 2628
- [Wal97] WALKER, R. F.: *Adaptive Multi-Scale Texture Analysis With Application to Automated Cytology*, University of Queensland, Diss., 1997