

Unscharfe Farbklassifikation und Strukturbewertung zur Echtzeitsegmentierung von Mikrodefekten

K.-H. Franke¹, H. Kempe¹, D. Kollhoff¹, M. Gräf², J. Wienecke², H. Other²

¹ Techn. Universität Ilmenau, Fakultät für Elektrotechnik und Informationstechnik

² Jenoptik Technologie GmbH, Jena

Zusammenfassung

Dieser Beitrag beschreibt einen Lösungsansatz zur Fehlerdetektion auf strukturierten Halbleiterwafern. Nach der Diskussion verschiedener Lösungsstrategien beim Aufbau von Inspektionssystemen für die Masken- und Waferkontrolle werden die wesentlichen Fehlergruppen, und die erforderlichen Leistungsparameter erläutert. Der Einsatz der Farbbildverarbeitung stellt eine wesentliche Neuerung bei der Waferinspektion dar. Mittels einer unscharfen (fuzzyfizierten) Farbklassifikation wird eine Vorsegmentierung des Waferbildes erreicht. Durch eine anschließende Bildfilterung und Klassifikation mittels Backpropagation-Netzwerk können sowohl kleine 'Spikes' als auch großflächige Fehler detektiert werden. Hervorzuheben ist die Echtzeitfähigkeit des vorgestellten Verfahrens, da marktübliche Spezialhardware zur Bildverarbeitung eingesetzt werden kann.

0. Einleitung

Der Trend in der Schaltungsherstellung zu ständig steigender Komplexität und Dichte der Halbleiterstrukturen führt zu einem wachsenden Bedarf an genauer und zuverlässiger Inspektion der Silizium-Wafer während des gesamten Herstellungsprozesses, d.h. nach jedem Prozeßschritt. Ziel ist es, durch Einsatz von bildverarbeitenden Inspektionssystemen die schwierige Aufgabe der zuverlässigen Defekterkennung zu automatisieren.

Eine wichtige Rolle spielt dabei die Farbinformation. Das Remissionsverhalten unterschiedlicher Materialien und optische Interferenzeffekte an dünnen Schichten führen zu Farben, die für die Schichten charakteristisch sind.

Da die einzelnen Strukturen auf einem Wafer verschiedene Farben besitzen, können Bilder anhand ihrer Farbvalenzen segmentiert werden. Gegenüber der Grauwertbildverarbeitung ist eine Vereinfachung der Segmentierung zu erwarten bzw. kann die Sicherheit der Segmentierung und damit der Fehlererkennung erhöht werden. In einigen Fällen wird die Fehlerdetektion erst durch die Nutzung der Farbinformation möglich.

Die hier vorgestellten Algorithmen zur Farbbildverarbeitung finden in dem In-

spektionsgerät "Defect Finder 2000" der Fa. Jenoptik Technologie GmbH ihre praktische Anwendung /Gräf94/. Das Forschungsprojekt wird durch das BMFT im Rahmen der europäischen JESSI-Initiative gefördert.

1. Zur statistischen Qualitätskontrolle bei Wafern

Beim Aufbau von Inspektionssystemen für die Masken- und Waferkontrolle gibt es zwei grundsätzlich zu unterscheidende Lösungsstrategien (Tafel 1).

Eine Variante geht vom Soll-Ist-Vergleich aus, wobei die Vorlage beim Vergleich von Bildern entweder durch einen Musterprüfling oder durch ein aus CAD-Daten synthetisiertes "golden template" geliefert wird. Je nach Verfahrensweise erfordert das das extrem präzise Positionieren des Waferträgers, zwei absolut identische Bilddatenkanäle bzw. die extrem exakte Synthese von Musterbildern.

Soll-Ist-Vergleich kann aber auch auf der Basis der CAD-Daten erfolgen. In diesem Fall wird die vollständige Analyse des realen Bildes erforderlich, d.h. die störsichere Segmentierung, Kantendetektion, die Approximation von Strukturelementen und die relationale Beschreibung der Szene müssen in Echtzeit beherrschbar sein.

zwei grundsätzlich unterschiedliche Prüfstrategien zur Fehlerdetektion		
Soll-Ist-Vergleich		Fehlerdetektion
Musterprüfling	CAD-Datensatz	
	Synthese virtuelles Sollbild	Analyse virtuelles Istbild zum CAD-Satz
Match der SW-, Grauwert- oder Farbpixelniveaus	Match von CAD-Daten	Pixel- und Strukturklassifikation
Fehlerbild	Fehlerliste	Fehlerbild
Zusammenhangsanalyse, Fehlerklassifikation, Statistik der Fehlerklassen		

Tafel 1: Soll-Ist-Vergleich und unmittelbare Fehleranalyse

Wegen der hohen technischen Anforderungen an Inspektionsgeräte auf der Basis des Soll-Ist-Vergleiches sind derartige Lösungen sehr kostenintensiv. Prinzipbedingt sind sie nur zur Maskeninspektion und auf den unteren Strukturierungsniveaus einsetzbar.

Die zweite, oben erwähnte Lösungsstrategie geht von einer Erkennung der Fehler aus, die aus Störungen und Abweichungen in den Parametern der technologischen

Prozesse, aus Materialdefekten, schlechter Qualität von Hilfsstoffen, Verunreinigungen bzw. Unregelmäßigkeiten der Kristallstruktur etc. hervorgehen.

Ansatzpunkte für die direkte Fehlerdetektion sind Farbvalenzen und Struktureigenschaften, die im Widerspruch zu den Entwurfsregeln, den Strukturparametern und den daraus resultierenden Bild- und Objektmerkmalen stehen.

Der hervorgehobene Pfad der unmittelbaren Fehlerdetektion und -bewertung stellt den entscheidenden Ansatzpunkt dar, vom Preis-Leistungsverhältnis günstigere Geräte gegenüber den auf dem Markt befindlichen zu fertigen. Er ist auf die statistische Prozeßkontrolle ausgerichtet, d.h. er dient dem Einfahren und der Überwachung von technologischen Prozeßschritten bei der Chipherstellung.

1.1 Die wesentlichen Fehlergruppen

Während der Halbleitertechnologie sich vordergründig von den Fehlerursachen und deren Bedeutung leiten läßt, liegen die Schwerpunkte beim "Bildverarbeiter" auf den visuellen Eigenschaften, also auf den Ansatzpunkten, die eine Erkennung und Klassifikation der Fehler möglich machen. Im Interesse der Praxisrelevanz der angestrebten Lösungen muß versucht werden, beide Aspekte zu vereinen. Das führt zu den folgenden Fehlergruppen, die zugleich einen Einblick in die Vielfalt und Komplexität der Aufgabenstellung geben:

- Blasen und Lackreste (Abb. 1)
- unvollständig ausgeätzte Strukturen (Abb. 2)
- Spikes, Stapelfehler, Gleitbänder (Abb. 3)
- Fremdpartikel
- Splitter (CVD), Löcher und "durchsichtige" Defekte
- Risse und Kratzer (Abb. 4)
- Leitbahnfehler und fehlende Strukturelemente
- verschlossene Strukturkomponenten (Kontakte)
- Versatz, dezentrale Strukturen



Abb. 1: Lackreste




Abb. 2: unvollständig geätzt




Abb. 3: Gleitbänder




Abb. 4: Kratzer

1.2 Die erforderlichen Leistungsparameter

Hoher Waferdurchsatz, zwischen 5 und 30 Strukturierungsebenen, typische minimale Strukturbreiten von $1\ \mu\text{m}$ bis $2\ \mu\text{m}$ und die minimalen zu detektierenden Defekte von $0.5\ \mu\text{m}$ stellen höchste Anforderungen an die verfügbare Rechentechnik, auch wenn im Sinne der statistischen Prozeßkontrolle nur ca. 20% der Chips pro Wafer vollständig kontrolliert werden sollen. Aus den Produktivitätsanforderungen läßt sich eine Inspektionszeit von 1 bis 2 min/cm^2 ableiten.

Aus der Forderung nach Verarbeitung in Videoechtzeit ergibt sich, daß sich die praktisch umsetzbaren Algorithmen auf die denkbar einfachsten reduzieren müssen und Hardwarelösungen mittels Spezialprozessoren erforderlich sind. Das gilt für alle erforderlichen pixelbezogenen Operationen wie Farbklassifikation, Filterung, Zusammenhangsanalyse, Kantenextraktion, Verdünnung und Vektorisierung. Die Endbearbeitung im Sinne der Analyse von Vektor- oder Regionenlisten erfolgt dann durch eine leistungsfähige Allzweck-CPU.

2. Das Bildverarbeitungskonzept zur Fehlererkennung in Videoechtzeit

Ausgangspunkt für das Bildverarbeitungskonzept ist die zugrunde liegende Geräteidee der statistischen Prozeß- und Qualitätskontrolle, die, wie oben bereits ausführlich begründet, von einer Erkennung der Fehler anhand ihrer Eigenschaften ausgeht. Das aus dem Entwurf stammende a priori-Wissen geht in Form von abstrahiertem Regelwissen ein.

Bei der Auswertung von Waferbildern sind die Auswirkungen der Abbildung dreidimensionaler Objekte mit Hilfe von Mikroskopen auf die Bildsignaleigenschaften zu beachten. Die minimalen Strukturbreiten und die kleinsten zu detektierenden Defekte liegen bei strukturierten Wafern in der Größenordnung der Schicht-

dicken und diese wiederum in der Größenordnung der Wellenlänge des als Informationsträger verwendeten Lichtes.

Aufgrund der verschiedenen mittleren Wellenlängen der drei Farbkanäle werden die Kanten von Objekten in den drei Farbkanälen unterschiedlich breit abgebildet, wobei die Breite zusätzlich von der Art des Objektes und der numerischen Apertur des Objektivs abhängig ist. Das bedeutet aber, daß sich in den Kantenbereichen die Farbwertanteile in Abhängigkeit vom Ort derart verschieben, daß Farbvalenzen mit völlig "neuer" Farbart entstehen. Die Farbart hat also mit den zu beiden Seiten der Strukturkante vorhandenen keine Gemeinsamkeit mehr, und der Farbort ist nahezu unbestimmt. Man erkennt im Bild bei hinreichender Pixelauflösung deutliche Farbsäume. Derartige Farbsäume stören die Farbbildauswertung erheblich, sollen doch Fehler unter anderem gerade dadurch einfach und sicher detektierbar sein, daß sie im allgemeinen von den "gesunden" Strukturelementen der Chips abweichende Farbvalenzen aufweisen.

2.1. Farbpixelklassifikation

Die Video-Echtzeitforderung einerseits und der einsetzbare Hardwareaufwand andererseits legen nahe, die Farbpixelklassifikation an die erste Stelle der Verarbeitungsschritte zu stellen. Weil durch sie in vielen Fällen ein wesentlicher Anteil an der Fehlererkennung erbracht werden soll, sind folgende Forderungen zu stellen:

- gute Beschreibung der Klassencluster im Farbraum und daraus resultierend gute Trenneigenschaften,
- Echtzeitfähigkeit, d.h. die Farbpixelklassifikation muß nach dem Datenflußprinzip realisierbar sein,
- einfache Belehrbarkeit des Klassifikators, die entweder automatisch abläuft oder bei der ein Technologe sein Expertenwissen einbringen kann.

Maximum-Likelihood-Ansatz

Der optimale Klassifikator ist der Klassifikator, der zu den geringsten Verlusten oder Kosten führt. Mit dem Maximum-Likelihood-Ansatz ist für jeden infinitesimalen Bereich dE des Farbraumes mit den Kostenfaktoren r_{ij} zu fordern, daß er der Klasse k zugeordnet wird, für die sich die geringsten Kosten ergeben.

$$\int_{I_1}^{I_0} p(z_i) r_{ki} w(E/z_i) dE < \int_{I_1}^{I_0} p(z_j) r_{\mu j} w(E/z_j) dE \quad (1)$$

$$\forall \mu, \{ \mu \in \{0, 1, \dots, k\} \}$$

(r_{ij} : Kosten, wenn bei Zustandsklasse z_j zur Klasse i entschieden wird.)

Mit einer parametrischen Beschreibung der Verteilungsdichten $w(E/z_i)$

$$p(z_i) = \frac{1}{(2\pi)^{m/2} \text{Det } \underline{K\underline{K}}_i^{1/2}} e^{-1/2 (F - F_{mi})^T \underline{K\underline{K}}_i^{-1} (F - F_{mi})} \quad (2)$$

sowie $r_{kl} = 1 - d_{kl}$ kommt man vereinfacht auf

$$l_i(E) = \ln p(z_i) + 1/2 \ln (\text{Det } \underline{K\underline{K}}_i) + 1/2 (F - F_{mi})^T \underline{K\underline{K}}_i^{-1} (F - F_{mi}) \quad (3)$$

und entscheidet zu Klasse k, wenn gilt:

$$l_k(E) > l_\mu(E) \quad \forall \mu \dots k \quad (4)$$

Die Nutzung der Farbklassifikation zur Fehlerdetektion geht nun davon aus, daß sich die zu den ungestörten Strukturkomponenten gehörenden, charakteristischen Farbvalenzen in ihrer Statistik durch ellipsoide Cluster beschreiben lassen, die durch Stichprobenanalyse geschätzt werden können [Schu93]. Die beiden Bilder zeigen einen Chipausschnitt und die zu den Strukturen gehörenden Cluster im 3D-Farbraum.

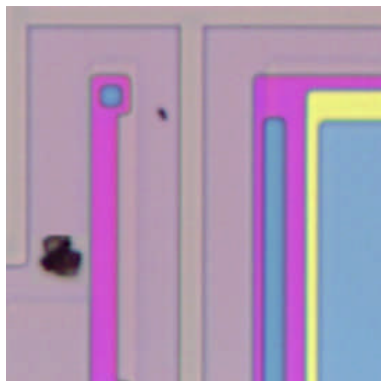


Abb. 5: Bildausschnitt

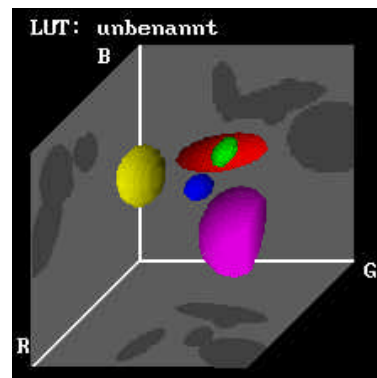


Abb. 6: Farbraum-Cluster

Die fehlerverdächtigen Pixel liegen außerhalb der Cluster (MAHALANOBIS-Abstand). Die weiter oben erwähnten Pixel der Farbsäume haben als solche jedoch ähnliche Eigenschaften und zur Differenzierung zwischen Fehlern und Farbsäumen müssen im Falle von Mikrodefekten die Eigenschaften der Umgebung herangezogen werden.

Das Wahrscheinlichkeitsbild ("Bekanntheitsbild")

Es leuchtet ein, daß durch einfache Schwellwertoperationen im Sinne des MAHALANOBIS-Abstandes die Aussagekraft bei der Betrachtung der lokalen Pixelumgebung durch verstärktes Kantenrauschen und Einschränkung der Vielfalt

beschnitten wird.

Deshalb wurde die Farbpixelklassifikation derart verändert, daß durch die Look-Up-Tabelle für jedes Pixel die Wahrscheinlichkeit für die Zugehörigkeit zu irgendeinem "Gutcluster" eingetragen wird. Die Höhe des erzeugten Grauwertes ist damit ein Maß für die "Bekanntheit" der Farbvalenz \underline{E} gemäß Stichprobe. Dieses Vorgehen entspricht einer Fuzzifizierung der Farbklassifikation.

Mit dem Multiplikationssatz der Wahrscheinlichkeitsrechnung erhält man:

$$P(\underline{E}) = \prod_{i=1}^n (1 + P_i(\underline{E})) \quad (5)$$

Abb. 7 zeigt das beschriebene Wahrscheinlichkeitsbild für das Beispiel aus Abb. 5 und in Abb. 8 ist das daraus ermittelte Fehlerbild vorweggenommen, das das eigentlich angestrebte Ergebnis darstellt.




Abb. 7: Wahrscheinlichkeitsbild



Abb. 8: Fehlerbild

2.2. Strukturklassifikation von Waferbildern

Ziel der Klassifikation von Strukturen auf Waferbildern ist es, Fehler an Hand von Umgebungsmerkmalen bezüglich eines Zentralpixels zu detektieren. Als Ausgangsdatenmaterial stehen die Ergebnisbilder der Farbklassifikation zur Verfügung. Ihre Grauwerte sind Ausdruck für die Wahrscheinlichkeit, daß das betrachtete Pixel zu einer Familie von Farbwertclustern gehört, die für fehlerfreie Chipstrukturen charakteristisch sind. Damit ist der hier beschriebene Algorithmus auf den Teil der zu detektierenden Fehlerpalette beschränkt, die sich in ihrer Farbvalenz von Clustern der Gutgebiete unterscheiden. Großflächige Fehlergebiete sind dann ohne weiteres durch Unterdrückung der unvermeidbaren Farbsäume segmentierbar. In der Regel wird aber zugleich das Registrieren von Mikrodefekten (z.B. Spikes) gefordert, die die gleichen linearen Ausdehnungen wie Farbsäume aufweisen. Einfache Tiefpaßfilterung reicht dann nicht mehr aus, Regelwissen und Strukturinformationen müssen

genutzt werden. Damit lassen sich die nach der Farbklassifikation im Sinne des Bekanntheitsbildes auftretenden Strukturen folgendermaßen einteilen:

Gutstrukturen:

- Gebiete mit hohen Grauwerten

Pseudofehler:

- Linienstrukturen der Breite von 1 - 3 Pixel als Trennlinien zwischen Gebieten bekannter Farben (Gutgebiete). Diese Linienstrukturen weisen zwar Vorzugsrichtungen auf, dennoch treten kurze Linienelemente in alle Richtungen an Rundungen und Ecken sowie Verzweigungen auf.
- Regionen allmählicher Veränderungen des Grauwertes mit dem Ort, bedingt durch ein Weglaufen der zugehörigen Farbwerte im Originalbild.

Fehler:

- Punktförmige Mikrodefekte mit vorrangig zentralsymmetrischen Eigenschaften. Die Größe beginnt bei ca. 3 Quadratpixeln.
- Homogene Schwarzgebiete, herrührend von unbekanntem Farbvalenzen im Originalbild. Der Übergang zwischen punktförmigen Fehlern und homogenen Schwarzgebieten ist fließend.

Die Umgebung der Pixel des Wahrscheinlichkeitsbildes selbst spannt einen hochdimensionalen Merkmalraum auf (64 Dimensionen in einer 8x8-Umgebung). Hardware und Echtzeitanprüche erfordern die Dimensionsreduzierung. Im erläuterten Beispielfall soll von zwei 8x8-FIR-Filtern und entsprechender Ausgangs-LUT ausgegangen werden, was zunächst auf den R^2 führt. Betrachtet man die Grauwerte der 8x8-Umgebung des Aufpunktes i,j vor der Filterung




Abb. 9: Faltungsoperation




Abb. 10: 2D-Subraum

als Komponenten eines Grauwertvektors $\underline{x}_{(i,j)}$ und ordnet die Filterkoeffizienten entsprechend zu einem Filtervektor \underline{a} , so führt die Faltungsfilterung (Skalarprodukt) zur Projektion des 64-dimensionalen \underline{x} auf die durch \underline{a} bestimmte Richtung.

$$y(i,j) = \mathbf{a}^T \mathbf{x}(i,j) \quad (6)$$

Filterbänke mit m linear unabhängigen Filtervektoren führen mithin in einen Subraum R^m , im Falle der oben beschriebenen Hardware- und Aufwandsrestriktionen also auf den im weiteren betrachteten Raum R^2 (Abb. 9 und 10).

Die eigentliche Klassifikation erfolgt nichtlinear über eine zweidimensionale Look-Up-Tabelle. Es ergibt sich also die Notwendigkeit, mittels geeigneter Verfahren die **Filterkoeffizienten** und eine **Look-Up-Tabelle** zu ermitteln. Voraussetzung hierfür ist das Vorhandensein einer Lernstichprobe, in der sowohl die Eigenschaften der Gutgebiete als auch die Eigenschaften der Fehler repräsentiert sind.

Heuristische Filterdimensionierung

Weiter oben wurden die geometrischen Eigenschaften der Gutgebiete und der Fehler beschrieben. Der hier erörterte Algorithmus ist insbesondere auf die Detektion von Spikes und Mikropartikeln ausgerichtet, die zu den häufigsten Fehlern gehören.

Punktförmige Gebilde lassen sich in bekannter Weise mittels Spot-Detektor lokalisieren. Eine einfach zu parametrisierende Form eines solchen Filtertyps stellt die zweite Ableitung einer 2-dimensionalen Gaußfunktion dar:

$$f_1(i,j) = \left(1 - \frac{r^2(i,j)}{s^2} \right) e^{-\frac{r^2(i,j)}{2s^2}} \quad (7)$$

Die Größe s bestimmt als einziger Parameter die Formeigenschaften. r beschreibt den Abstand zum Mittelpunkt des Filterkerns.




Abb. 11: Clusterbild




Abb. 12: Trennfunktion

Es ist leicht einzusehen, daß bei der Vielfalt der Fehler und der hohen Ähnlichkeit einiger Pseudofehler (Ecken und Verzweigungen von Strukturkanten) eine Clustierung mit nur einem solchen Filter nicht möglich ist. Erforderlich und aus der Sicht der Hardwarepotenzen realisierbar ist ein weiteres Filter, das eine möglichst korrelationsfreie Clustierung erlaubt, d.h. dessen Filtervektor senkrecht zu dem des Spot-Detektor steht. Ein Filter in Form eines Tiefpasses, etwa die Gaußfunktion selbst, realisiert diese Forderung hinreichend:

$$f_2(i,j) = e^{-\frac{r^2(i,j)}{2s^2}} \quad (8)$$

Die Filterergebnisse $F_{1,2}$ ergeben sich durch Faltung der Pixelgrauwerte $x(i,j)$ mit den aus den Übertragungsfunktionen $f_{1,2}$ abgeleiteten Filterkoeffizienten:

$$F_{1,2}(i,j) = \sum_{m=-3}^3 \sum_{n=-3}^3 f_{1,2}(m,n) \cdot x(i+m, j+n) \quad (9)$$

Die Abb. 11 zeigt das Clusterbild für den eben beschriebenen Fall. Die eingekreisten Gebiete enthalten die Stichprobenvektoren von Fehlern, während die Filterergebnisse der Gutgebiete nicht eingekreist sind. Die Abb. 12 beschreibt die mittels neuronalem Netz berechnete Diskriminanzfunktion, deren Ermittlung im folgenden erläutert wird.

Ermitteln einer Trennfunktion

Die auf den verwendeten Hardwarekarten vorhandenen LUT's weisen in der Regel einen Adressraum von 16 Bit und eine Datenbreite gleicher Größe auf. Nach Aufbereitung des 2D-Merkmalraumes (jedes Merkmal zu 8 bit) sind leistungsfähige Methoden der Dimensionierung des in Frage kommenden Klassifikators (LUT) erforderlich.

Untersucht wurde die interaktive Dimensionierung, der Nächste-Nachbar-Klassifikator sowie die Anwendung von Backpropagation-Netzen /Krat90/. Während die interaktive Dimensionierung subjektiv und fallbezogen ist und der Nächste-Nachbar-Klassifikator Schwächen im Falle dünn besetzter Stichproben aufweist, sind mit dem Backpropagation-Netz die besten Ergebnisse erzielt worden. Nachteilig ist, daß Stichproben von Fehlern zur Belehrung erforderlich sind.

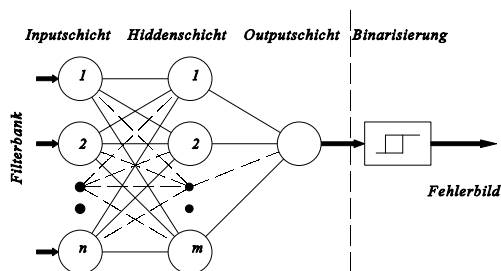


Abb. 13: Backpropagation-Netzwerk als Klassifikator

Netze gemäß Abb.13 mit zwei Eingangsneuronen (2D-Merkmalraum) und einer Hiddenschicht zu zehn Elementen führten zu gut ausgeformten Diskriminanzfunktionen (Abb. 12), die dann in eine zugehörige Look-Up-Tabelle zur Echtzeitklassifikation umrechenbar ist /Kemp93/.

3. Literatur

/Gräf94/ Gräf, M.; Wienecke, J.; Albrecht, D.; Franke, K.-H.: Dem Fehler auf der Spur. productronic 1994, Heft 3, S. 12-16

- /Gräf92/ Gräf, M. u.a.: System- und Gerätekonzeption ABIKO. Bericht im Projekt ABIKO; Jenoptik Technologie GmbH 1992
- /Kemp93/ Kempe, H.: Strukturklassifikation von Waferbildern, TU Ilmenau, Fak. E/I, FG Technische Erkennung, Kurzbericht (13S.)
- /Krat90/ Kratzer, K.P.: Neuronale Netze: Grundlagen und Anwendungen. Carl Hanser Verlag München Wien 1990
- /Schu93/ Schuster, R., Ahmad, S.: Modellbasierte Beschreibung von Farbhistogrammen und Segmentierung von Farbbildern, Mustererkennung 1993, Springer-Verlag, S. 305-312

Autoren:

- Doz. Dr.-Ing. habil. K.-H. Franke, Dipl.-Ing. H. Kempe, Dipl.-Ing. D. Kollhoff: TU Ilmenau, Fakultät für Elektrotechnik und Informationstechnik, 98684 Ilmenau, PSF 327, Tel. (03677) 692607 od. 692626, Fax: (03677) 691152, e-mail: franke@e-technik.tu-ilmenau.de
- Dipl.-Ing. M. Gräf, Dipl.-Ing. H. Other, Dr. J. Wienecke: Jenoptik Technologie GmbH, Prüssingstr. 41, 07739 Jena, Tel. (03641) 653351, Fax: (03641) 653687