

Farbpixelklassifikation mittels partitionierender Clusteralgorithmen und Vergleich mit neuronalen Ansätzen

Karl-Heinz Franke
FG Graphische Datenverarbeitung
Technische Universität Ilmenau
Postfach 0565, 98684 Ilmenau
Karl-Heinz.Franke@prakinf.tu-ilmenau.de

Torsten Machleidt
Zentrum für Bild- und Signalverarbeitung e. V. Ilmenau
Langewiesener Str. 16
98693 Ilmenau

Abstract: Im Beitrag werden Verfahren der partitionierenden Clusteranalyse untersucht und unter dem Gesichtspunkt der präzisen Beschreibung komplexer Cluster bewertet. Die so erfaßten Klassenräume erlauben die Trennung strukturierter Objekte von Fehlerregionen, deren Eigenschaften oft nicht oder nur unzureichend bekannt sind. Das Verfahren der adaptiven Distanzen hat sich als Leistungsfähigste erwiesen. Selbstorganisierende neuronale Algorithmen führen, hinreichend viele Freiheitsgrade vorausgesetzt (neuronales Gas), bis auf wenige Abstriche zu vergleichbaren Ergebnissen. Erste Schritte zur Echtzeitfähigkeit der Verfahren in der Klassifikationsphase sind in [Mac-95] beschrieben.

1 Einleitung und Motivation

Farbpixelklassifikation und -Segmentierung spielen in der Farbbildverarbeitung eine wesentliche Rolle. Die Auswahl geeigneter methodischer Ansätze hängt neben der verfahrensbedingten Leistungsfähigkeit in starkem Maße auch von der zu lösenden Aufgabe und den damit verbundenen Randbedingungen ab.

Als Problemstellung wird die präzise Modellierung von komplexen Clustern im Farbraum vertieft. Diese Vorgehensweise scheint u.a. immer dann besonders geeignet, wenn die Detektion von Fehlern bei der Qualitätsinspektion von farbig strukturierten, industriellen Produkten im Vordergrund steht. Die Situation ist in solchen Fällen oft dadurch gekennzeichnet, daß die Eigenschaften des fehlerfreien Produktes beschreibbar sind („Gut“-Klassen der Strukturkomponenten), die Beschreibung der Fehler mangels vollständiger oder zumindest typischer Fehlerkataloge in der Regel aber fehlt.

Die Trennung der „Gut“-Klassen untereinander (mehrere fehlerfreie Strukturkomponenten eines komplexen Musters) ist in diesen Fällen nicht erforderlich bzw. wünschenswert. Die gute Abtrennung des komplexen Gesamtclusters vom Rest des Raumes gewährleistet die Fehlerdetektion auf der Basis der verwendeten Merkmale (z.B. Farbe).

Wegen der komplexen Form der „Gut“-Klasse erweist sich die Beschreibung als äußerst problematisch. Als eine Möglichkeit der Charakterisierung dieser Klasse werden Clusteralgorithmen im weiteren vertieft.

2 Clusteralgorithmen

Bei den Clusteralgorithmen handelt es sich um multivariate Verfahren, die alle verfügbaren Merkmale gleichzeitig berücksichtigen. Ähnlichkeits- bzw. Unähnlichkeitsmaße bewerten die Beziehungen zwischen den einzelnen Datenobjekten, so daß eine Einteilung in unterschiedliche Cluster (Klassen, Gruppen, Klumpen) möglich wird.

Die Clusteranalyseverfahren lassen sich im wesentlichen in vier Gruppen einteilen (Abb. 1). Während die hierarchische Clusteranalyse Forderungen an die Homogenität in den Klassen in den Vordergrund stellt, gehen Mischverteilungsverfahren von bekannten Verteilungen in den Klassen aus, deren Parameter zu schätzen sind.

Die verteilungsfreien Verfahren nehmen anhand von Stichproben eine verteilungsfreie Schätzung der Mischdichte vor, wobei eine Orientierung an relativen Maxima erfolgt. Im Weiteren werden nur die partitionierenden Clusterverfahren vertieft, da eine für die einleitend geschilderte Problematik einerseits eine möglichst präzise Beschreibung der Cluster erforderlich ist, jedoch andererseits nicht zwischen den einzelnen „Gutclustern“ unterschieden werden muß (Gut-Schlecht-Problematik).

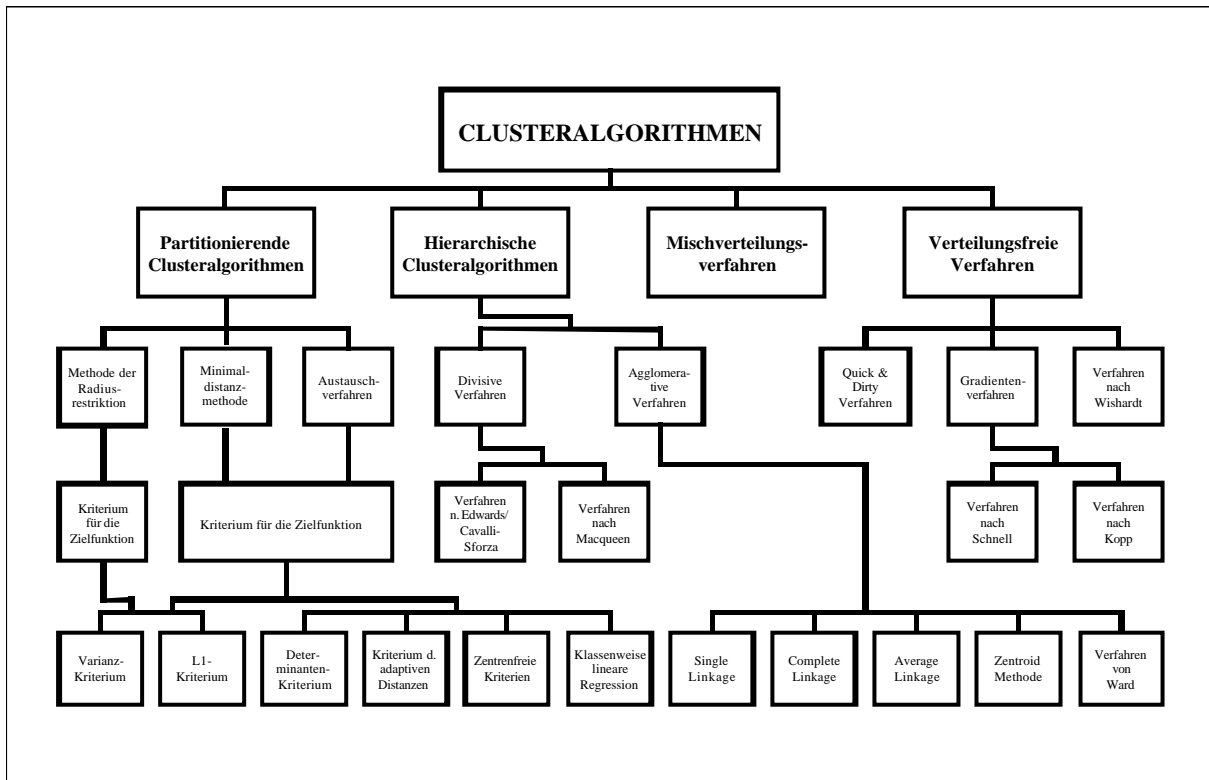


Abbildung 1 : Einteilung der verschiedenen Clusteralgorithmen

3 Partitionierende Clusteralgorithmen

Die Zerlegung einer Objektmenge in g Cluster wird als Partition bezeichnet. Partitionierende Clusteralgorithmen erstellen verschiedene Partitionen. Mit Hilfe eines Gütekriteriums wird die Qualität der Partition gemessen. Es wird die Partition gesucht, welche hinsichtlich des Gütekriteriums optimal ist. Die partitionierenden Clusteralgorithmen werden in der Regel nach den Kriterien ihrer Zielfunktion benannt.

3.1 Kriterien zur partitionierenden Clusteranalyse

Einfache Metriken führen zu verhältnismäßig geringem Rechenaufwand. Dazu gehören die Euklidische- und die L_1 -Metrik. Während erstere die Verteilung durch Hyperkugeln mit gleichem Radius approximiert, führt das zweite Kriterium auf eine Approximation durch Hyperquader gleicher Größe und Orientierung.

Sowohl das Determinantenkriterium als auch das Kriterium der adaptiven Distanz verwenden die aufwendigere Mahalanobis-Metrik. Das Determinantenkriterium läßt dabei nur Hyperellipsoide

gleicher Größe und Orientierung zu. Die größten Freiheitsgrade liefert das Kriterium der adaptiven Distanz, das auf Hyperellipsoide variabler Größe und Orientierung führt.

Zur Minimierung der aufgeführten Zielfunktionen wurden die Verfahren Radiusrestriktion (RRM) und Minimaldistanz (MDM) untersucht.

Bei dem auch als Kernobjekt-Aufbauverfahren [Boc-74] bezeichneten RRM handelt es sich um ein schnelles Verfahren, das keine Anfangspartition benötigt. Ausgangspunkt der Analyse sind sogenannte Kernobjekte. Die gesuchten Klassen werden dann nach und nach um das entsprechende Kernobjekt gebildet. Hauptproblem bei diesem Verfahren ist die richtige Wahl des Radius R für eine bestimmte maximale Klassenzahl K . In diesem Zusammenhang haben sich Radiussschätzungen in Bezug auf die konkreten Daten bewährt [Muc-92].

Die Minimaldistanzmethode minimiert die Zielfunktion (optimale Partition) indirekt über die Distanz. Dabei wird von einer zufällig gesetzten oder durch vorausgeschaltete Clusteralgorithmen (hierarchisch, RRM) gefundenen Startpartition C ausgegangen [Boc-74, Muc-92]. Sie ist auf alle angeführten Zielfunktionen anwendbar.

3.2 Anwendung auf eine 2D-Verteilung, Ergebnisse und Wertung

Ausgehend von einem Waferausschnitt erfolgte zur Demonstration der Verfahren eine Beschränkung auf die Farbwerte Rot und Grün. Zum Erreichen der Minimaldistanzpartition wurde das Minimaldistanzverfahren und für das Varianzkriterium zusätzlich das Radiusrestriktionsverfahren verwendet.

In Abb. 2 sind die Ergebnisse dargestellt, wobei die Elemente der Lernstichproben farbig hervorgehoben sind. Mit dem Varianz- und dem L_1 -Kriterium (MDM) konnte das Ziel, die Verteilung möglichst eng zu umschließen nur teilweise erreicht werden. Alle anderen Verfahren liefern bessere Ergebnisse. Die sehr guten Ergebnisse des Varianzkriteriums (RRM) hängen von der Radiussschätzung ab, die gegebenenfalls nachkorrigiert werden muß.

Erwartungsgemäß gut schneidet die Mahalanobis-Metrik ab, die auch bei nur vier Clustern eine hinreichende Beschreibung liefert.

4 Anwendung von Clusteralgorithmen zur Farbbildanalyse

Die Anwendung der Clusteralgorithmen zur Analyse von Farbbildern soll anhand der Waferinspektion gezeigt werden. Abbildung 3 und 4 zeigen zwei typische Waferausschnitte mit Fehlern.

Aus dem Bildmaterial wurde ein „Gut-Bereich“ ausgewählt und für die Belehrung im RGB-Raum verwendet. Es wurde das Kriterium der adaptiven Distanzen für 10 Cluster ausgewählt.

Die Abbildungen 5 und 6 zeigen die Bekanntheitsbilder. Je dunkler der Grauwert, um so weiter ist ein Farbvektor von den belehrten Clustern entfernt.




Abbildung 5: Bekanntheitsbild (ZMD002)

Abbildung 6: Bekanntheitsbild (207)

Die fehlerhaften Bereiche heben sich deutlich ab. Abbildungsbedingte Farbsäume an Strukturberandungen werden durch eine Strukturklassifikation unterdrückt.

5 Vergleich der Clusteralgorithmen mit neuronalen Algorithmen

Neuronale Verfahren lassen sich in ähnlicher Weise einsetzen. Dabei hat sich das Neuronale Gas [Mar-94] in Bezug auf die zur Diskussion stehende Aufgabe am leistungsfähigsten erwiesen.

Das Neuronale Gas baut im Gegensatz zum Kohonen-Netz die Verbindungsstruktur zwischen den Neuronen erst in der Belehrung auf, was zu erhöhter Adaptivität führt.

Abb. 7 zeigt die gute Nachbildung der weiter oben bereits verwendeten Beispielverteilung. Typisch für selbstorganisierte neuronale Verfahren ist, daß für Bereiche mit großen Häufigkeiten (rechts unten) viele Neuronen verwendet werden. Dadurch wird der obere Bereich mit wenigen großen Clustern nicht so eng umschrieben wie gewünscht. Ein Ausweg besteht in der Vergrößerung der Clusterzahl.




Abbildung 8: Bekanntheitsbild (ZMD002)


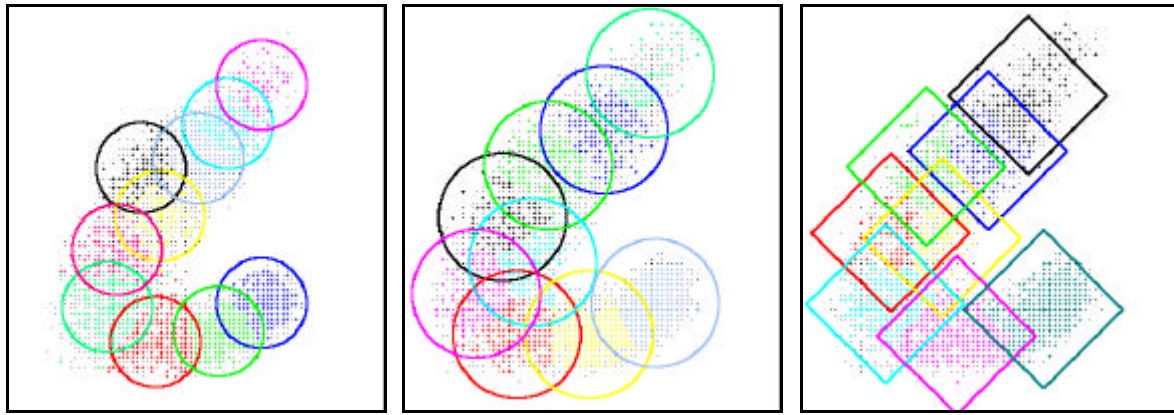


Abbildung 9: Bekanntheitsbild (207)

Vergleicht man die Ergebnisse der Untersuchungen an den Waferbildern (Abb. 8 und 9) mit denen des Kriteriums der adaptiven Distanzen, so sind kaum Unterschiede zu erkennen. Auch hier sind die Abweichungen von der Lernstichprobe gut sichtbar. Der oben angesprochene Nachteil des Neuronalen Gases, kommt, bedingt durch die Art der Fehler, bei den gezeigten Beispielen nicht zum tragen. Wegen der einfacheren Metrik (euklidisch), die dem neuronalen Algorithmus zugrundeliegt, können damit kürzere Klassifikationszeiten erreicht werden.

Literaturverzeichnis

- [Boc-74] Bock, H. H.: Automatische Klassifikation, Vandenhoeck & Ruprecht, Göttingen, 1974
- [Mac-94] Machleidt, T.: Untersuchungen von Einsatzmöglichkeiten von Kohonen-Netzen zur Fehlerdetektion in Waferbildern, TU-Ilmenau, Fakultät für Allgemeine und Theoretische Elektrotechnik, Studienarbeit, 1994
- [Mac-95] Machleidt, T.: Approximation mehrdimensionaler Verteilungen mittels ausgewählter Clusteralgorithmen, Diplomarbeit, ZBS Ilmenau e.V., 1995
- [Mar-94] Martinetz T.; Schulen K.: Topology Representing Networks, IN: Neural Network Vol. 7 No. 3, S. 507-522, 1994
- [Muc-92] Mucha, H.-J.: Clusteranalyse mit Mikrocomputern, Akademie Verlag GmbH, Berlin, 1992
- [Spä-83] Späth, H.: Cluster-Formation und-Analyse, R. Oldenbourg Verlag GmbH, München, 1983



Varianzkriterium (RRM)

Varianzkriterium (MDM)

L_1 -Kriterium (MDM)



Determinantenkriterium (MDM)

adaptiven Distanzen (MDM)

adaptiven Distanzen (MDM)

Abbildung 2: Ergebnisse der einzelnen Kriterien für die 2D-Verteilung (Anzahl Cluster = 10 bzw. 4)




Abbildung 3: Waferbild ZMD002




Abbildung 4: Waferbild 207




Abbildung 7 : Ausbildung der 10 Cluster für das Verfahren des Neuronalen Gases