

Künstliche Neuronale Netze zur optischen Qualitätskontrolle textiler Nähte

Claus Bahlmann *
Diplomarbeit, Universität Bielefeld, 1997 †

Betreuer:
Prof. Dr. Helge Ritter
Dipl.-Phys. Gunther Heidemann

19. Mai 1997

*bahlmann@informatik.uni-freiburg.de

†<http://lmb.informatik.uni-freiburg.de/people/bahlmann/data/bahlmann-seams1997.pdf>

Inhaltsverzeichnis

1. Einleitung	5
1.1. Ziel der Arbeit	5
1.2. Vorgehensweise	5
2. Textile Nähte	8
2.1. Die Naht—ein wertbestimmender Bestandteil von Bekleidungsstücken	8
2.2. Der Entstehungsprozeß einer Naht am Beispiel des Doppelsteppstiches	8
2.3. Nahtfehler	9
2.4. Einsatzbereiche einer Nahtkontrolle	10
2.5. Welligkeit als Maß für Nahtqualität	11
3. Bildaufnahme	13
3.1. Aufbau der Aufnahmeapparatur	13
3.1.1. Die Lage des Stoffes	13
3.1.2. Aufbau der Kamera	13
3.1.3. Aufbau der Beleuchtungseinrichtung	14
3.2. Aufnahmeparameter	18
3.2.1. Bildausschnitt	18
3.2.2. Auflösung	18
3.2.3. Beleuchtungsstärke und Blendeneinstellung	20
3.3. Aufnahme der Trainings- und Testbeispiele	21
4. Bildpositionierung	23
4.1. Hough Transformation	23
4.1.1. Die Hessesche Normalenform als Geradendarstellung	23
4.1.2. Die Transformation	25
4.2. Nahtdetektor	26
4.3. Bildverschiebung	26
5. Das Neuronale Netz	30
5.1. Neuronale Netze zur Repräsentation des Merkmalsraumes	30
5.2. Die Kohonenkarte	30
5.3. Das verwendete Kohonennetz	32
5.3.1. Das Kohonennetz als Klassifikator	32
5.3.2. Berücksichtigung unterschiedlicher Varianzen in den Merkmalen	35
5.3.3. Die Einstellung der Netzparameter	35
6. Merkmalsextraktion	37
6.1. Vorgehensweise bei der Beurteilung der Merkmale	37
6.2. Erste Ansätze der Merkmalsbildung	38
6.2.1. Fourier-Transformation	39
6.2.2. Definition der Merkmalstypen	40
6.2.3. Definition der Klassifikatoren	40
6.2.4. Resultate der Probeklassifikationen	42
6.2.4.1. Der NMSE der Probeklassifikationen	42
6.2.4.2. Die Verwechslungsmatrix der Probeklassifikationen	44
6.2.4.3. Der MSE als Maß der Wahrscheinlichkeit einer Fehlklassifikation	46
6.2.4.4. Untersuchung der im Trainingsprozeß entstandenen Kohonenkarte	46

Inhaltsverzeichnis

6.3. Weiterentwicklung der Merkmale	50
6.3.1. Die Korrelation von Fourier-Spektrum und Notenklassen	51
6.3.2. Definition der erweiterten Klassifikatoren	52
6.3.3. Resultate der Probeklassifikationen mit den erweiterten Merkmalen	52
6.3.3.1. NMSE und MSE der Probeklassifikation	54
6.3.3.2. Die Verwechslungsmatrix der Probeklassifikationen	54
6.3.3.3. Untersuchung der beim Training entstandenen Kohonenkarte	56
6.4. Zusammenfassung der Klassifikationsergebnisse	56
7. Zusammenfassung und Ausblick	59
7.1. Zusammenfassung	59
7.2. Ausblick	59
A. Mathematische Methoden und verwendete Verfahren	61
A.1. Verfahren zur Maximierung der Grauwertvarianz bei der Bildaufnahme	61
A.2. Der Korrelationskoeffizient	61

1. Einleitung

1.1. Ziel der Arbeit

Diese Arbeit untersucht im Rahmen einer Kooperation des INSTITUTS FÜR NÄHTECHNIK (IFN) und der Arbeitsgruppe NEUROINFORMATIK der TECHNISCHEN FAKULTÄT der UNIVERSITÄT BIELEFELD die Realisierbarkeit und das Vorgehen bei einer kameragestützten automatisierten Qualitätskontrolle textiler Nähte mit Hilfe neuronaler Netze. Im Vordergrund werden dabei Untersuchungen von Nähten bei Bekleidungstextilien stehen. Die Arbeit ist als Realisierbarkeitsstudie konzipiert und soll erste Methoden für die Implementierung eines automatisierten Klassifikationssystems und die Bedingungen untersuchen, unter denen es in der Praxis arbeiten kann.

Ein solches System könnte bei der betrieblichen Textilverarbeitung geeignet sein, innerhalb der Qualitätssicherung die bisher von Fachkräften durchgeführte, zeitintensive und mehr subjektive Beurteilung durch eine objektivierte maschinelle Kontrolle zu ersetzen.

Um dem gestellten Ziel näher zu kommen, werden unter anderem folgende Fragestellungen zu untersuchen sein:

- Wie können optische Signale in das maschinelle System verwertbar übertragen werden (Aufbau einer Aufnahmeapparatur, Gestaltung der Lichtverhältnisse u.ä.)?
- Durch welche Merkmale sind die verschiedenen Qualitätsabstufungen in den Nähten gekennzeichnet und wie lassen sie sich mathematisch repräsentieren?
- Wie kann ein neuronales Netz die Zusammenhänge zwischen Merkmalen und Qualitätsklassen am besten adaptieren?

1.2. Vorgehensweise

Die Strategie, die in dieser Arbeit zu einer Implementation eines Klassifikationssystems verfolgt wurde, stellt Abbildung 1.1 dar: In einem ersten Schritt ist ein Aufnahmesystem zu erstellen, welches die Struktur von Textilnähten differenziert erfassen kann und auf ein (Grauwert-) Bild abbildet (a). Anschließend wird das Bild in eine genormte Position verschoben, um eventuelle Uneinheitlichkeiten in der Position der Nähte, die während der Aufnahme entstanden sind, auszugleichen (b). Im nächsten Schritt wird aus dem hochdimensionalen Grauwertbild ein Merkmalsvektor berechnet, der geeignet ist, Information über die Qualität der jeweiligen Naht zu kodieren (c). Die Merkmalsvektoren werden dann dazu benutzt, ein neuronales Netz auf die Zusammenhänge zwischen Merkmalsraum einerseits und der Nahtqualität andererseits in einem überwachten Lernprozeß zu trainieren (d). Wenn das Netz erfolgreich trainiert worden ist, dann ist es fähig, auf die Eingabe eines Merkmalsvektors mit der entsprechenden Qualitätsbeurteilung zu antworten (e).

Die Gliederung der Arbeit orientiert sich an der oben beschriebenen Strategie: In Kapitel 2 werden die grundlegenden Prinzipien der Nähetechnik, Qualitätskriterien von Textilnähten und die derzeit gültigen Standards bei der Qualitätskontrolle von Nähten dargestellt. Kapitel 3 beschreibt den Aufbau des Kamerasystems, mit dessen Hilfe die Nähte für eine nachfolgende automatische Klassifikation digital erfaßt werden. In Kapitel 4 wird der Bildpositionierer vorgestellt. Dies ist ein Verfahren, welches eventuelle Aufnahmeungenauigkeiten bereinigt, indem es die Nahtbilder in eine einheitliche Position transformiert. Kapitel 5 motiviert und erklärt die Verwendung des neuronalen Netzes (das *Kohonennetz*),

1. Einleitung

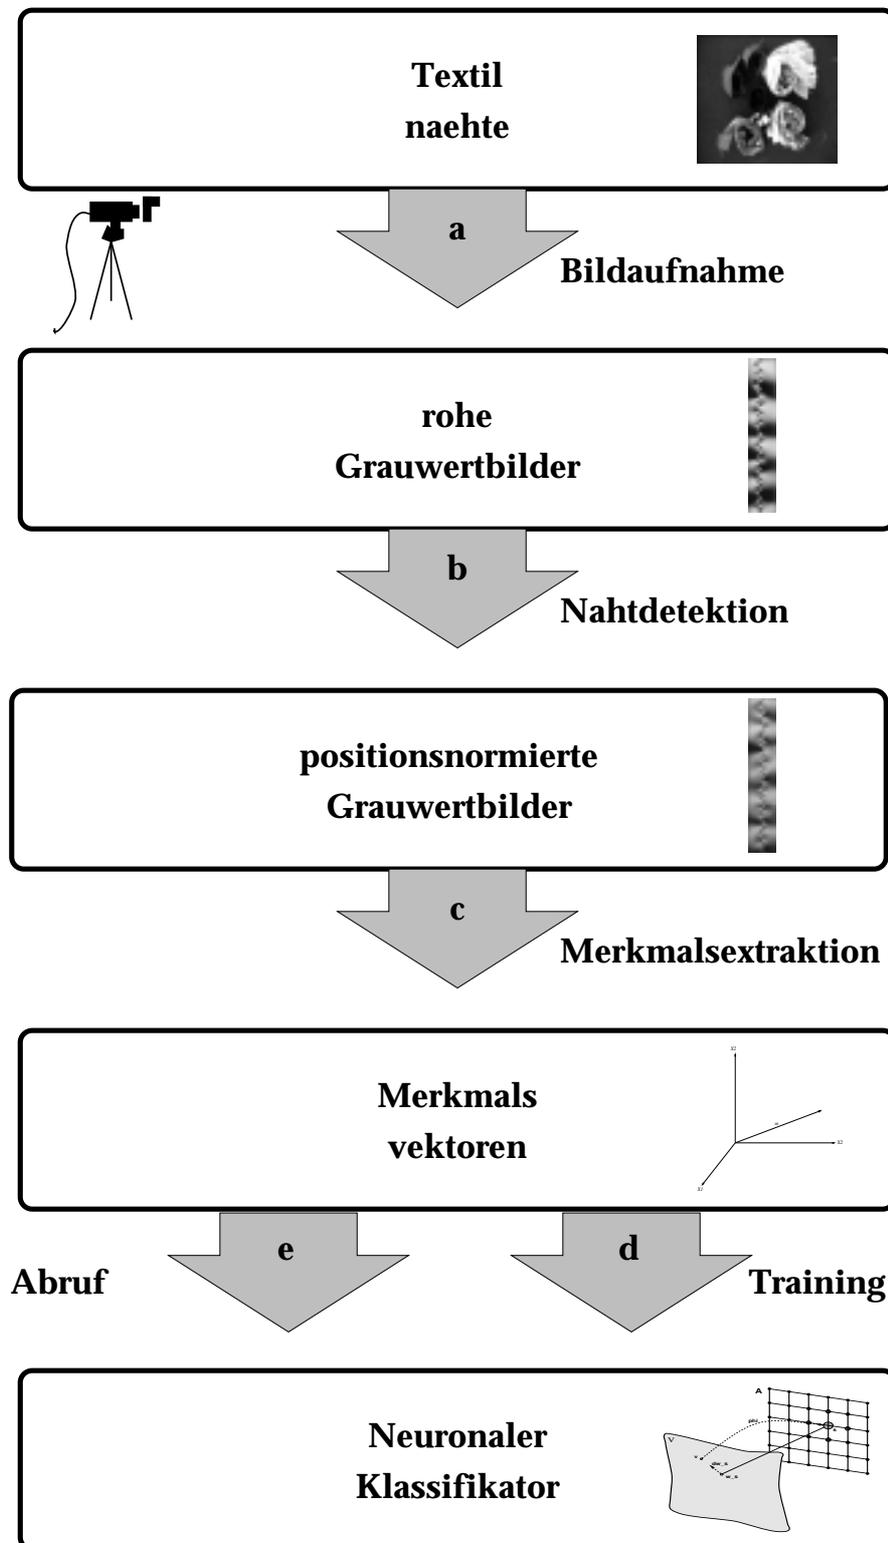


Abbildung 1.1.: Schematischer Aufbau des Klassifikationssystems

welches für die Klassifikation verwendet wurde. In Kapitel 6 erfolgt schließlich die Darstellung der Klassifikationsmerkmale, die aus den Nahtaufnahmen gewonnen werden. Ergebnisse, die ein Klassifikationssystem mit Hilfe dieser Merkmale herausgefunden hat, werden hier dokumentiert und die Merkmale anhand der Ergebnisse weiterentwickelt. Kapitel 7 faßt die erarbeiteten Ergebnisse zusammen und schlägt Ansätze vor, mit denen das automatische Klassifikationssystem in späteren Untersuchungen ausgebaut werden könnte.

2. Textile Nähte

Bei Textilien wird zwischen

1. Bekleidungstextilien (Hosen, Jackets, Hemden u.a.)
2. Heimtextilien (Vorhänge, Tischdecken, Bettwäsche)
3. technischen Textilien (Autopolster, Airbag, Gurte , Zeltplanen)

unterschieden. Diese drei Gruppen weisen neben Unterschieden auch zahlreiche Gemeinsamkeiten auf. In dieser Arbeit soll der Schwerpunkt auf die Untersuchung von Bekleidungstextilien gelegt werden.

2.1. Die Naht—ein wertbestimmender Bestandteil von Bekleidungsstücken

Die Beurteilung von Kleidungsstücken erfolgt nach mehreren Kriterien: Neben ästhetischen Überlegungen spielen dabei noch weitere Gesichtspunkte eine erhebliche Rolle, wie zum Beispiel Materialeigenschaften bzw. -qualität der verwendeten Stoffe. Ein entscheidendes Beurteilungskriterium liegt jedoch in der Ausführung der Nähte. Der Nähvorgang stellt einen Teil des Fertigungsprozesses dar, der die Qualität des Kleidungsstückes maßgeblich bestimmt. Die zentrale Bedeutung der Nähte für das Bekleidungsstück läßt sich von ihren Funktionen ableiten:

- Sie sollen die einzelnen zugeschnittenen Teile dauerhaft zusammenhalten. Fehlerhafte Nahtstellen können sich schneller lösen oder sogar zu Rissen im Textil führen.
- Sie können als optische Gestaltungselemente dienen, die das fertige Produkt entscheidend in Aussehen bzw. Eigenart prägen. So erwartet man in der Nahtausführung bei eleganten Kleidungsstücken eher eine glatte Naht, während bei saloppen Teilen wie Jeans teilweise sogar eine wellige Naht gewünscht wird. Letztere sind allerdings nicht ohne Auswirkungen auf Haltbarkeit und Tragverhalten, weil an den vorstehenden Nahtstellen der Abrieb des Gewebes besonders intensiv ist. Dies bewirkt zwar einerseits den gewünschten Effekt einer typischen Jeanstextur, beeinträchtigt aber andererseits in erheblichem Maße die Haltbarkeit des Produktes.

Es ist naheliegend, daß in der Praxis der Bekleidungsfertigung die Nahtkontrolle im Rahmen der Qualitätssicherung einen hohen Stellenwert einnimmt. Sie ist eine wichtige Voraussetzung dafür, daß ein Betrieb den Anforderungen einer qualitätsorientierten Produktion gerecht werden kann.

2.2. Der Entstehungsprozeß einer Naht am Beispiel des Doppelstepstiches

Das Nähen von Bekleidungsartikeln erfolgt heute mit Hilfe von Maschinen. Ein häufig verwendeter Nahttyp ist die Doppelstepstichnaht (DStSt, Stichtyp 301). Sie entsteht auf folgende Weise: Zwei Fäden, der Ober- und der Unterfaden, werden zwischen den Geweben, die verbunden werden sollen, durch die Maschine miteinander *verschlungen*. Diese Verschlingung hält die Stoffe zusammen. Im Idealfall ist die Stelle, an der sich Ober- und

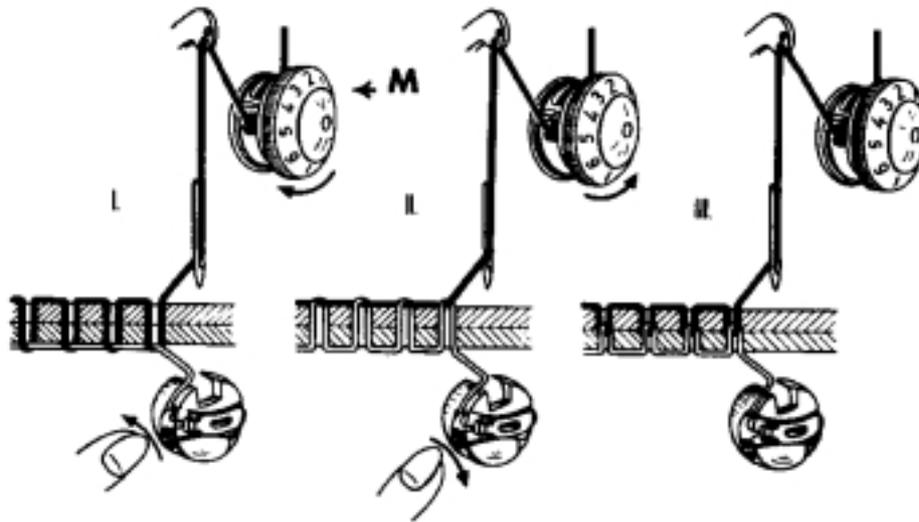


Abbildung 2.1.: Das Prinzip der DStSt-Naht: Ober- und Unterfaden verschlingen sich zwischen den zu vernähenden Geweben. Bild III zeigt eine optimale Naht. Bilder I und II zeigen Fälle, in denen Ober- bzw. Unterfadenspannung zu schwach eingestellt wurden. Dies ist ein Grund, warum es in der Naht zu Spannungen und dadurch zu Welligkeiten kommen kann. (Abbildung aus [Schmucker, 1964])

Unterfaden verschlingen, die Berührungsstelle der aufeinanderliegenden Gewebe. Abbildung 2.1 III. zeigt diesen Fall.

Das Nähen mit der Maschine stellt einen komplexen Arbeitsablauf dar. Erst die Abstimmung einer Reihe von komplizierten Teilvorgängen untereinander läßt eine fehlerfreie Naht entstehen. Bei einigen Bauelementen der Maschine, die an der Nahtbildung wesentlich beteiligt sind, kann man diverse Einstellungen so verändern, daß es gelingt, gezielt auf den Nähvorgang Einfluß zu nehmen. Dadurch können die Nähbedingungen optimiert werden, was zum Beispiel bei einer Verwendung unterschiedlicher Materialien erforderlich ist. Durch Einstellung geeigneter Parameter läßt sich unter anderem folgendes variieren (siehe [Doering, 1975]):

- Stichdichte
- Nähfußdruck
- Fadenspannung

Zur richtigen Einstellung der Maschinen bedient man sich bewährter Erfahrungswerte. Es muß jedoch bedacht werden, daß die eingestellten Parameter zu wechselseitigen Auswirkungen führen können. Eine theoretische Vorhersage von Arbeitsergebnissen oder gar eine sichere Voreinstellung der Nähmaschine sind aufgrund dieses Sachverhaltes oft nicht möglich. Diesem Nachteil hilft man in der Praxis durch Verwertung experimentell gewonnener Werte ab. Auf welche Weise dies genau geschieht, wird in Kapitel 2.4 beschrieben.

2.3. Nahtfehler

Bei den meisten Kleidungsstücken sind glatte Nähte das Kriterium für eine gute Qualität. Sie entstehen, wenn die an der Nahtbildung beteiligten Fäden (Ober- und Unterfaden) an den Kontaktstellen der Gewebe verschlungen sind (siehe Abbildung 2.1 III.). Die verwendeten Stoffteile sind gleichmäßig und spannungsfrei miteinander verbunden.

Abweichungen hiervon gelten als Nahtfehler. Sie führen innerhalb der Naht zu Spannungen, die Verformungen der Stoffoberfläche zur Folge haben. Solche Fehler können auch noch während des Gebrauchs des Kleidungsstückes, zum Beispiel beim Tragen oder bei der Reinigung, auftreten.

2. Textile Nähte

Die häufigsten Ursachen für Nahtfehler und deren Folgen sind: (aus [Ferd. Schmetz G.m.b.H, 1975])

1. *Falsch eingestellte Ober- oder Unterfadenspannung*: Dies hat zur Folge, daß die Verschlingung nicht in der Mitte des Stoffes stattfindet (Abbildung 2.1 I. und II. zeigen diesen Fall).
2. *Ungünstige Kombination von Gewebe und Nähfaden*: Beide Materialien schrumpfen nach dem Nähen während des Gebrauchs durch z.B. Waschen unterschiedlich stark zusammen. Besonders gravierend ist dieser Effekt bei der gleichzeitigen Verwendung von Natur- und Kunstfasern oder Baumwolle und Wolle.
3. *Ein zu dicker Nähfaden*: Er kann die Gewebefäden verdrängen, was zu einem Verschieben der Gewebestruktur führt. (*Verdrängungskräuseln*)
4. *Unterschiedliche Reibungskoeffizienten*: Ist die Reibung zwischen den beiden Gewebelagen geringer als zwischen oberer Gewebelage und Nähfuß, wird die untere Gewebelage vom Transporteur schneller nach vorne geschoben als die obere. Dies hat einen Gewebestau bei der oberen Lage und damit ein Kräuseln zur Folge. (*Transportkräuseln*)

2.4. Einsatzbereiche einer Nahtkontrolle

Bei der Bekleidungsherstellung werden heute in zwei verschiedenen Anwendungsbereichen Nahtkontrollen vorgenommen:

1. Bei der Zwischen- und Endkontrolle von fertigen Kleidungsstücken:
Sie dient der Qualitätssicherung der hergestellten Produkte und soll verhindern, daß fehlerhafte Stücke in den Verkauf gelangen. Eine Fachkraft führt eine Sichtkontrolle der gefertigten Artikel durch, um diese gegebenenfalls nachzubessern oder auszusortieren. Bei der Fehlersuche gilt der Naht ein besonderes Augenmerk.
2. Bei der Kontrolle von Probestreifen:
Hierbei werden nicht die fertigen Artikel selbst, sondern eigens für diesen Zweck angefertigte Probestreifen begutachtet. Dies geschieht mit der Zielsetzung, eine Nähmaschine optimal für den Nähvorgang einstellen zu können. Verschiedene Stoffe mit unterschiedlichen Materialeigenschaften erfordern eine differenzierte Einstellung von Maschinenparametern wie Fadenspannung, Stichlänge, Transportart und -geschwindigkeit sowie Nähfußdruck (vergleiche Kapitel 2.2). In der praktischen Durchführung näht die Fachkraft probeweise zunächst längliche Stoffstreifen mit unterschiedlichen Einstellungen. Anschließend begutachtet sie die Ergebnisse und stellt die Maschinenparameter entsprechend dem besten Ergebnis ein. Beispiele solcher Probestreifen werden in Abbildung 2.3 gezeigt.

Den Einsatz eines automatisierten Klassifikationssystems kann man sich in beiden Bereichen, also sowohl in der Klassifikation der Endprodukte als auch in der Probestreifen-Klassifikation, vorstellen. Dabei ist der Einsatz im zweiten Bereich sicherlich leichter. Probenähte sind einfacher gestaltet als eine Naht von fertigen Kleidungsstücken. Zum einen verlaufen sie in einer geraden Linie und zum anderen treten keine zusätzlichen Spannungen z. B. durch herunterhängende Ärmel bei Jacketts o. ä. auf.

Um die prinzipielle Realisierbarkeit eines automatisierten Klassifikators zu untersuchen, soll in dieser Arbeit zunächst der einfachere Weg gegangen und die Untersuchungen anhand der „Probenähte“ durchgeführt werden. Es wird jedoch darauf geachtet, daß die benutzten Methoden und Ergebnisse auf den zweiten Fall übertragbar sind und das Ergebnis dadurch erweiterbar bleibt.

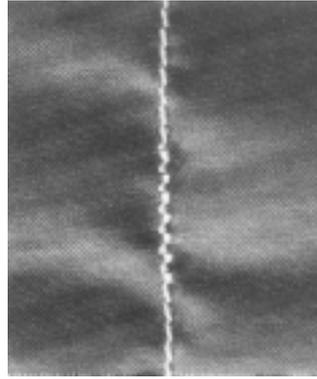


Abbildung 2.2.: Eine wellige Naht (aus [Ferd. Schmetz G.m.b.H, 1975])

2.5. Welligkeit als Maß für Nahtqualität

Im vorigen Kapitel sind verschiedene Nahtfehler aufgezählt worden. Während die Ursachen für Nahtfehler verschiedenartig sein können, lassen sich bezüglich ihrer sichtbaren Erscheinungsformen auffällige Gemeinsamkeiten feststellen: Infolge der in den einzelnen Stofflagen entstandenen Spannungen kommt es an den Nahtstellen zu *Welligkeiten* oder *Kräuselungen*. Abbildung 2.2 zeigt solch eine typische Welligkeit.

In der Bekleidungsfertigung gibt es einen Standard, anhand dessen die Welligkeiten der in Kapitel 2.4 erwähnten Probenähte beurteilt und klassifiziert werden können. Dieser Standard beschreibt fünf verschiedene, diskrete Stufen von Welligkeit—von „überhaupt nicht gewellt“ (Note 5) bis „sehr stark gewellt“ (Note 1). Die Fachkraft führt die Qualitätskontrolle so aus, daß sie jede zu beurteilende Naht mit Aufnahmen von fünf Referenznähten, die die fünf Notenklassen definieren, vergleicht. Die Notenklasse der Referenznaht, die der zu beurteilenden am ähnlichsten liegt, bestimmt das zu vergebende Urteil. Die Referenznähte werden in Abbildung 2.3 gezeigt.

Die wichtigsten Vergleichskriterien sind dabei in Längsrichtung sich erstreckende Wellen. Das Augenmerk wird sowohl auf eine Wellenbildung hoher Frequenz in der Streifenmitte nahe der Naht als auch auf eine langwellige am Streifenrand gerichtet.¹

Der Vergleich mit den Referenznähten hat den Vorteil, daß sich der Begutachter an einem absoluten Qualitätsstandard orientieren kann. Subjektive Kriterien, die eine objektive Beurteilung beeinflussen könnten, sollen dadurch unterdrückt werden, wie z.B. Bewertungstendenzen aus vorangegangenen Stoffserien. Auch dürfen Qualitäts- bzw. Materialunterschiede der verwendeten Stoffe nicht in die Benotung einfließen, damit kein „Notenbonus“ für einen schlecht zu bearbeitenden Stoff gewährt wird.

¹Laut Aussage von Frau Donath, IFN

2. Textile Nähte

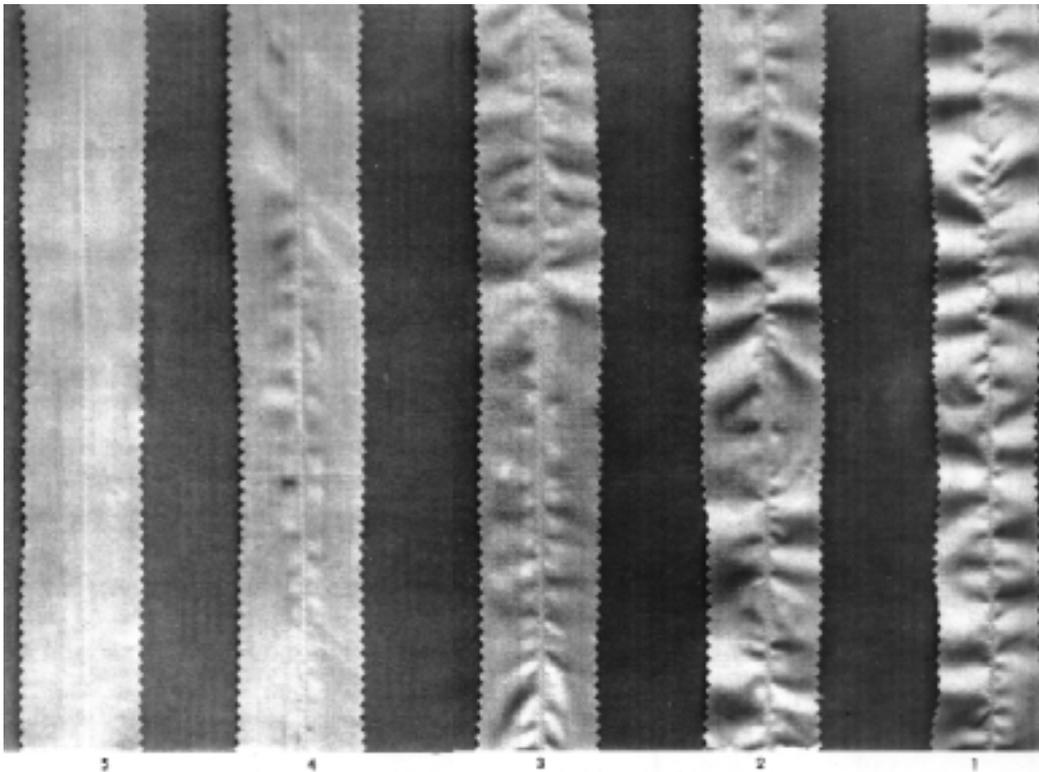


Abbildung 2.3: Referenznoten für die Nahtbeurteilung, links die Note 5 („überhaupt nicht gewellt“), rechts die Note 1 („sehr stark gewellt“). Anhand dieser Referenzstreifen führt die Nähfachkraft die Beurteilung durch.

3. Bildaufnahme

3.1. Aufbau der Aufnahmeapparatur

Das Ergebnis der hier untersuchten, automatisierten Qualitätskontrolle hängt entscheidend von einem geeigneten Aufbau der Aufnahmeapparatur ab. Daher ist es von Nutzen, die Vor- und Nachteile verschiedener Szenarien aufzuzählen und abzuwägen. Im wesentlichen geht es bei dem Einrichten der Aufnahmeapparatur um das Positionieren

- des Objektes, also des *Stoffes*
- der *Kamera* und
- der *Beleuchtung*

Diese Punkte bilden eine Einheit und müssen aufeinander abgestimmt sein.

3.1.1. Die Lage des Stoffes

Der Stoff ist das zentrale Element innerhalb der gesamten folgenden Untersuchung. Aus diesem Grund sollte er, wenn der Aufbau der Aufnahmeapparatur definiert wird, den Ausgangspunkt bilden.

Man kann ihn in einer

1. *horizontal liegenden*,
2. *vertikal hängenden* oder
3. *schrägen*

Position aufnehmen.

Um eine Auswahl zu treffen, muß vorher überprüft werden, in welcher Lage der Stoff die Struktur der Welligkeiten möglichst unverfälscht wiedergibt.

Dieses Kriterium wurde in einem Versuch untersucht, in dem ein Stoffstreifen auf einer Unterlage befestigt und mit dieser in eine horizontale und vertikale Lage gedreht wurde. Hierbei wurde deutlich, daß das Erscheinungsbild des Stoffes von seiner Lage unabhängig ist. Dieser Tatbestand wird dadurch erklärbar, daß das Eigengewicht des Stoffes zu gering ist, um die relativ feste Struktur der Wellen zu verformen.

Daher bleibt die Wahl der verwendeten Stofflage ohne Auswirkung auf die Untersuchungsergebnisse. Allerdings erscheint die Alternative der *hängenden* Naht vorteilhafter, weil dadurch die Naht ohne weitere Hilfsmittel an einer geraden Linie zentriert wird.

Die Auswahl auf diese Variante wird außerdem dadurch bestätigt, daß in der Bekleidungsindustrie der Standard ISO/DIS 7770 [DIS, 1981] für die Begutachtung eingeführt wurde, der ebenfalls eine solche Position des Stoffes vorschreibt.

3.1.2. Aufbau der Kamera

Der Aufbau der Kamera wird hauptsächlich durch die Ausrichtung des Kameraobjektivs auf die Stoffnähte bestimmt. Dabei bieten sich folgende Vorschläge für eine Kameraposition an:

1. *frontale* Position

3. Bildaufnahme

2. *seitliche* Position (das Längsprofil aufnehmend)

3. *schräge* Position

Eine *frontale* Kameraposition (Vorschlag 1) hat den Vorteil, daß die Kamera den gesamten Nahtstreifen erfassen kann. Damit wird Information aus zwei Dimensionen des Probestreifens (in Quer- wie in Längsrichtung) gewonnen. Die dritte Dimension in der Struktur der Probenähte (die Wölbungen der Wellen) könnte sogar durch eine geschickte Wahl der Beleuchtung auf das Bild übertragen werden (vergleiche späteres Kapitel 3.1.3).

In der *seitlichen* Position (Vorschlag 2) erfaßt die Kamera das Profil der Probestreifenlängsseite. Dadurch werden eventuelle Welligkeiten des Stoffes direkt räumlich sichtbar. Nachteilig wirkt sich bei dieser Kameraposition aus, daß nur Information über den Stoffrand und nicht über die Nahtoberfläche in die Aufnahme einfließt. Sämtliche Information über die Querstruktur der Naht als auch über längsgerichtete Welligkeiten in der Nahtmitte wird durch diese Kameraperspektive bei der Aufnahme nicht erfaßt. Gegen diese Perspektive spricht auch die Tatsache, daß sie sich nur auf die Aufnahme von Nahtprobestreifen anwenden läßt, wie sie in Kapitel 2.4 beschrieben wurde. Die Qualitätskontrolle fertiger Kleidungsstücke ist mit dieser Methode ausgeschlossen.

Der dritte Vorschlag besteht darin, die Kamera aus einer *schrägen* Position, das heißt aus einem Winkel ungleich 90° zur Streifenebene, aufnehmen zu lassen. Dagegen spricht jedoch, daß diese Kamerasicht den Nahtstreifen perspektivisch verzerrt erscheinen läßt. Eine derartige Verzerrung würde in diesem Fall die Bildverarbeitung unnötig erschweren. Da dieser Blickwinkel keine Vorteile gegenüber der frontalen Kameraposition besitzt, gibt es keinen ausschlaggebenden Grund für diesen Vorschlag.

Die oben angestellten Überlegungen sprechen für die Auswahl einer *frontalen* Kameraperspektive (Vorschlag 1), da diese die meiste Information aus den Probestreifen in das Bild einbringt.

3.1.3. Aufbau der Beleuchtungseinrichtung

In diesem Kapitel wird gezeigt, daß die Beleuchtungsrichtung einen großen Einfluß auf die Leistungsfähigkeit des Klassifikationssystems hat. Deshalb ist es sinnvoll, störende Lichteinflüsse wie das Außenlicht auszuschließen und die Bildaufnahme in einem abgedunkelten Raum durchzuführen.

Für die Position der Beleuchtung gibt es zwei Alternativen

1. *frontaler* Lichteinfall

2. *streifender* Lichteinfall

Der Vorteil der *frontalen* Beleuchtung besteht darin, daß der Stoff gleichmäßig ausgeleuchtet wird und so die Nahtaufnahmen durch eine homogene Helligkeitsverteilung gekennzeichnet sind.

Die *streifende* Beleuchtungsvariante zeichnet aus, daß sie die dreidimensionale Struktur der Probestreifen optimal auf das zweidimensionale Bild abbildet: In den Schatten der Nahtwellen befindet sich die Information über die Wellenfrequenzen und deren Amplituden, die die Güte der Naht letztlich bestimmen. Im Bild können die Schatten durch das Auftreten dunkler Grauwerte erkannt werden. Folglich kommt dem Licht also neben der Funktion des „Aufhellens“ noch eine informationsgenerierende Eigenschaft zu.

Mit der streifende Ausleuchtung treten jedoch auch Probleme auf:

- Die Helligkeiten können auf den Nahtstreifen sehr inhomogen verteilt sein. Bei einer oberhalb der Naht angebrachten Beleuchtung erscheint der obere Teil der Naht heller als der untere. Die Ausprägung der Helligkeitsunterschiede ist abhängig vom Winkel- und Längenabstand der Beleuchtung.
- Die absolute Helligkeit ist wegen des schrägen Auftreffens der Lichtstrahlen geringer als beim frontalen Lichteinfall. Dadurch können insbesondere dunkle Stoffe zu spärlich ausgeleuchtet werden. Um diesen Nachteil auszugleichen, muß mit einer hohen Lichtintensität beleuchtet werden.

3.1. Aufbau der Aufnahmeapparatur

Beleuchtungswinkel α	8°	13°	20°	30°	90°
Klassifikationsfehler MNMSE	0.50	0.33	0.25	0.31	0.71

Tabelle 3.1.: Zusammenfassung der Klassifikationsfehler MNMSE für die verschiedenen Beleuchtungswinkel

Die angeführten Vor- und Nachteile lassen an dieser Stelle noch keine Entscheidung zugunsten einer der beiden Alternativen zu. Auch kann man nicht sicher sagen, welches der optimale Einfallswinkel für das Licht bei einer streifenden Beleuchtung ist.

Um zu einer Entscheidung zu gelangen, sind Aufnahmeserien unter verschiedenen Beleuchtungsszenarien durchgeführt worden. Die Resultate, die ein vorläufiges Klassifikationssystem für diese Aufnahmen liefert, sollen bei der Entscheidungsfindung helfen. Zu diesem Zweck wurden Aufnahmen mit folgenden Winkeleinstellungen α (= der Winkel, den die Beleuchtungsachse mit der Nahtebene einschließt)¹ durchgeführt:

$$\alpha_i = 8^\circ, 13^\circ, 20^\circ, 30^\circ, 90^\circ$$

Abbildungen 3.1, 3.2 und 3.3 zeigen Bilder von Nähten aus drei verschiedenen Notenklassen (Noten 1, 3 und 5), die mit den fünf gewählten Beleuchtungswinkeln α_i aufgenommen wurden.

Zusätzlich zu den Aufnahmen sind in den Abbildungen die Varianzen der Grauwerte des entsprechenden Bildes und die Resultate von durchgeführten Testklassifikationen eingetragen. Die Resultate sind als „gemittelter normalisierter mittlerer quadratischer Fehler“ (MNMSE) dargestellt. Der MNMSE berechnet sich als Mittelung des NMSE aus $8 \cdot 12 = 96$ Testklassifikationen. Die einzelnen Testklassifikationen unterscheiden sich jeweils in der Einstellung der Gittergeometrie des verwendeten Kohonennetzes (8 verschiedene) und der verwendeten Merkmale (12 verschiedene).²

In den Abbildungen kann man erkennen, daß unter einer stark *streifenden* Beleuchtung ($\alpha = 8^\circ$) ein höherer Kontrast in der Aufnahme entsteht (vergleiche auch die Grauwert-Varianzen) als bei weniger stark streifender. Besonders ausgeprägt ist der hohe Kontrast bei welligen Nähten, weil dort einerseits die dem Licht abgewandte Seite eines Wellenberges im Schatten liegt und andererseits auf der der Beleuchtung zugewandten Seite das Licht fast senkrecht einfällt.

Bei der *frontalen* Beleuchtung sind die Kontraste kaum noch zu erkennen (Abbildung 3.3). Hier gilt sogar, daß die Grauwert-Varianzen der Aufnahmen für die verschiedenen Notenklassen kaum variieren. Dies schlägt sich auch in den Klassifikationsergebnissen nieder. Der MNMSE beträgt bei dieser Beleuchtungsart 0.71.

Der Umkehrschluß, daß die Beleuchtungsart, die im höchsten Kontrast ($\alpha = 8^\circ$) resultiert, die besten Klassifikationsresultate liefert, gilt hingegen nicht. In Tabelle 3.1, die die MNMSE's zusammenfaßt, ist zu erkennen, daß die Testklassifikationen für diese Einstellung ebenfalls ein schlechtes Ergebnis (MNMSE = 0.50) liefern. Das beste Resultat (MNMSE = 0.25) kommt mit einem Beleuchtungswinkel von 20° zustande.

Die Einstellung des für die Untersuchungen schließlich verwendeten Beleuchtungswinkels α wird mit Rücksicht auf den erzielten Klassifikationsfehler vorgenommen. Dies führt, wie bereits erwähnt, zu einer Einstellung des Winkels auf $\alpha = 20^\circ$. An späterer Stelle (in Kapitel 6.3.1) wird eine Erklärung gegeben, weshalb sich dieser Winkel durch die besten Klassifikationsresultate auszeichnet.

Mit den Untersuchungen der Kapitel 3.1.1, 3.1.2 und 3.1.3 kommt es im Ganzen zu der Aufnahmesituation, die in Abbildung 3.4 zusammengefaßt ist. Sie weist eine große Ähnlichkeit zu dem in der Textilindustrie verwendeten Standard zur Begutachtung von Probenähten [DIS, 1981] auf.

¹Der Winkel $\alpha = 90^\circ$ entspricht also der frontalen Beleuchtungsvariante.

²Auf das verwendete Neuronale Netz und die Merkmale, anhand derer die Klassifikation durchgeführt wurde, soll an dieser Stelle noch nicht eingegangen werden. Dies wird in den Kapiteln 5 und 6 nachgeholt.

3. Bildaufnahme

Beleuchtungswinkel 8°			
	Note 1	Note 3	Note 5
Aufnahme:			
Grauwert-Varianz:	5820	2658	1253
Klassifikationsergebnis (MNMSE):	0.50		

Beleuchtungswinkel 13°			
	Note 1	Note 3	Note 5
Aufnahme:			
Grauwert-Varianz:	4914	1725	889
Klassifikationsergebnis (MNMSE):	0.33		

Abbildung 3.1.: (Teil 1) Aufnahmen der Probestreifen unter verschiedenen Beleuchtungswinkeln. Für jeden Winkel sind dieselben drei Streifen, die von Fachkräften mit den Benotungen 1, 3 und 5 beurteilt worden sind, abgebildet. Die Zahlenwerte unterhalb jeder Aufnahme geben die Varianz der Grauwerte des Bildes an. Weiterhin ist das Resultat einer Testklassifikation als MNMSE (gemittelter normalisierter mittlerer quadratischer Fehler) angeführt. Der MNMSE berechnet sich aus den NMSE's verschiedener Testklassifikationen, die sich in den Gittergeometrien des benutzten Kohonennetzes und in den verwendeten Merkmalen unterscheiden. (Teil 2 und 3 folgen auf den nächsten beiden Seiten.)

3.1. Aufbau der Aufnahmeapparatur

Beleuchtungswinkel 20°			
	Note 1	Note 3	Note 5
Aufnahme:			
Grauwert-Varianz:	2346	692	444
Klassifikationsergebnis (MNMSE):	0.25		

Beleuchtungswinkel 30°			
	Note 1	Note 3	Note 5
Aufnahme:			
Grauwert-Varianz:	1527	585	408
Klassifikationsergebnis (MNMSE):	0.31		

Abbildung 3.2.: (Teil 2) Beschreibung siehe [Abbildung 3.1](#)

3. Bildaufnahme

Beleuchtungswinkel 90°			
	Note 1	Note 3	Note 5
Aufnahme:			
Grauwert-Varianz:	204	201	200
Klassifikationsergebnis (MNMSE):	0.71		

Abbildung 3.3.: (Teil 3) Beschreibung siehe Abbildung 3.1

3.2. Aufnahmeparameter

3.2.1. Bildausschnitt

Der Bildausschnitt bezeichnet die Größe des Ausschnitts der Probenähte, der in der Aufnahme festgehalten wird. Er setzt sich aus seiner *Breite* und *Länge* zusammen.

Die in den Stoffstreifen enthaltene Information ist, wie in Kapitel 2.5 erörtert wurde, eine sich in Längsrichtung erstreckende Nahtwelligkeit. Die Frequenz dieser Welligkeit ist zudem in Abhängigkeit von der Entfernung zur Nahtmitte unterschiedlich groß (vergleiche Abbildung 2.3). Zur Merkmalsgenerierung sollten alle diese Typen von Welligkeiten zur Verfügung stehen. Daher wird die *Breite* des Bildausschnittes zu 4 cm gewählt, was somit der Breite eines Probestreifens entspricht.

Die *Länge* muß so groß gewählt sein, daß die Welligkeiten bzw. die Wellenlängen der Nahtwellen ausreichend genau bestimmt werden können. Dabei ist zu beachten, daß das in Kapitel 6 verwendete Verfahren zur Wellenlängenbestimmung—die Fourier-Analyse—eine Diskretisierung bezüglich der Wellenzahlen durchführt. Für eine genaue Messung der Welligkeit sollten in der Gesamtlänge etwa 4–5 ganze Wellen enthalten sein. Eine Messung an den Nähten aus Abbildung 3.1 zeigte, daß die Wellenlängen bis zu 5 cm betragen. Dies führt auf eine zu verwertende Länge von $4 \cdot 5 = 20$ cm.

Zusammengefaßt errechnet sich der aufzunehmende Bereich auf eine Größe von

$$4 \text{ cm} \times 20 \text{ cm} \quad (3.1)$$

3.2.2. Auflösung

Die Aufnahmen werden im Computer durch eine Bildmatrix dargestellt, in der im vorliegenden Fall der Grauwertaufnahmen die Grauwertstufen an den entsprechenden Stellen eingetragen werden. Die *Auflösung* bezeichnet die Anzahl der Spalten und Zeilen dieser Matrix. Für den erforderlichen Bildausschnitt (3.1) muß eine geeignete Auflösung gefunden werden. Folgende Überlegungen spielen bei der Entscheidung eine Rolle:

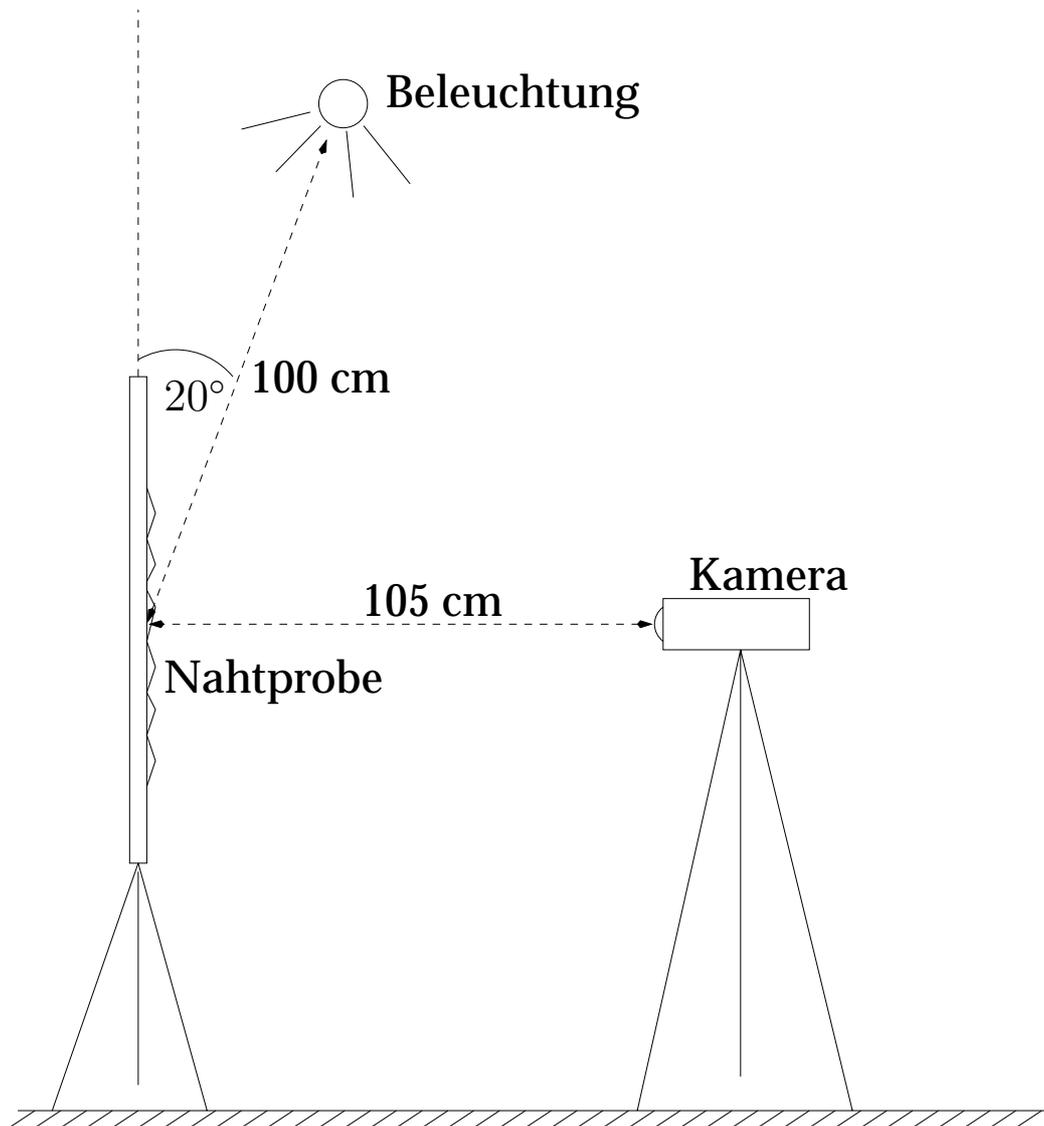


Abbildung 3.4.: Aufnahmeapparatur, mit der die Aufnahme der Probenähte durchgeführt wurde.

3. Bildaufnahme

- Es dürfen keine zu großen Sprünge in den Grauwerten benachbarter Pixel auftreten, damit die Welligkeiten sowohl in vertikaler als auch in horizontaler Richtung originalgetreu wiedergegeben werden.
- Es sollte gewährleistet sein, präzise auf Positionen x in Querrichtung der Naht zugreifen zu können. Anhand von 1-pixel-breiten Teilstreifen, die durch x verlaufen, sollen die *positionsabhängigen* Frequenzen der Welligkeit, wie sie in Kapitel 2.5 beschrieben wurden, untersucht werden.
- Die Auflösung muß so groß gewählt werden, daß eine nachträgliche Rotation des Bildes (die eventuell notwendig ist, um leicht schiefe Aufnahmen nachträglich anzugleichen, siehe Kapitel 4) nicht zu großen Diskretisierungsfehlern führt.
- Um mit den Grauwerten in Längsrichtung eine „Fast Fourier Transform“ (FFT) effizient durchführen zu können, wäre als Längsauflösung eine Zweierpotenz von Vorteil. [Press et al., 1992]³
- Die Größe des Bildausschnittes (3.1) definiert das Verhältnis „Breite/Länge“ zu $1/5$. Es ist jedoch zu beachten, daß der bei der Aufnahme verwendete „Datacube“ das Bild in Längsrichtung mit dem Faktor $4/3$ verlängert. Das Verhältnis „Breite/Länge“ verringert sich also auf $\frac{1}{5 \cdot 4/3} = \frac{3}{20}$.

Um eine präzise Zugriffsmöglichkeit zu gewährleisten (Punkt 2), sollte die Breite ≈ 50 – 100 Pixel betragen. Zusammen mit der Forderung nach einer Zweierpotenz in Längsrichtung und dem „Breite/Länge“-Verhältnis bietet sich die Auflösung

$$80 \times 512 \text{ Pixel} \quad (3.2)$$

an. Es hat sich herausgestellt, daß auch die übrigen Bedingungen (eine originalgetreue Objektwiedergabe und die Möglichkeit zur Rotation) mit dieser Auflösung problemlos zu erfüllen sind.

3.2.3. Beleuchtungsstärke und Blendeneinstellung

Die Beleuchtungsstärke und die Blende sind zwei Größen, mit denen man die Helligkeit des Bildes beeinflussen kann. Ein helles Bild kann sowohl durch eine hohe Beleuchtungsintensität als auch eine große Blende hervorgerufen werden. Für eine gute Bildqualität ist es jedoch erstrebenswert, mit einer hohen Beleuchtungsintensität zu arbeiten. Oft kann man zwar eine zu geringe Beleuchtungsintensität durch eine große Blende kompensieren, jedoch ist in diesem Fall eine geringe Schärfentiefe die Konsequenz, was eine schlechtere Bildqualität bedeutet.

Die beste Vorgehensweise beim Einstellen dieser beiden Parameter ist daher, eine starke Beleuchtung zu verwenden und gegebenenfalls die Blende zu verkleinern, wenn das Bild zu hell ist. Es wird daher im folgenden nicht mehr auf die Beleuchtungsstärke, sondern nur noch auf die Einstellung der Blende eingegangen.

Die Probenähte liegen im allgemeinen in unterschiedlichen Farben und Materialien vor. Dies hat zur Konsequenz, daß bei einer einheitlichen Blendeneinstellung die verschiedenen Gewebe in unterschiedlichen Helligkeiten wiedergegeben werden. So ergibt eine weiße Naht bei gleicher Blendeneinstellung eine wesentlich hellere Aufnahme als eine rote oder schwarze Naht. Neben der Gewebefarbe hat das Material Einfluß auf die Helligkeit: Nylon reflektiert das Licht stärker als Wolle und bewirkt daher ein helleres Bild. Diese Helligkeitsunterschiede erschweren es, ein Klassifikationssystem stoffartübergreifend zu realisieren.

Allerdings ist es erstrebenswert, eine Klassifikation der Stoffproben unabhängig von ihrer Farbe bzw. ihres Materials vorzunehmen. Dies erfordert jedoch eine Normierung der Aufnahmen. Hierbei ergeben sich die Alternativen:

³Für die Querrichtung wird keine FFT berechnet. Daher entfällt bei der Querauflösung die Forderung nach einer Zweierpotenz.

3.3. Aufnahme der Trainings- und Testbeispiele

1. eine nachträgliche Normierung durch bildverarbeitende Methoden (z.B. durch eine Histogrammeinebnung oder eine Neuskalierung der Grauwerte)
2. eine Helligkeitsnormierung bereits bei der Aufnahme durch ein angepaßtes Einstellen der Blende

Eine Normierung nach Punkt 1 führt jedoch nicht zu einem echten Informationsgewinn, sondern nur zu einer Aufbereitung der alten Information. Es ist zu erwarten, daß das Bild nach der Normierung für den menschlichen Betrachter zwar besser zu erkennen ist, jedoch liegt für den Computer nach informationstheoretischen Gesichtspunkten die gleiche Information vor wie vor der Normierung.

Dagegen kann eine Helligkeitsnormierung, die bereits während der Aufnahme vorgenommen wird (Punkt 2), einen echten Informationsgewinn bedeuten. Sie könnte den Bildkontrast erhöhen und daher den zur Verfügung stehenden Grauwertbereich [0...255] optimal ausfüllen. Sie ist somit der nachträglichen Normierung (Punkt 1) vorzuziehen.

Ein geeignetes Verfahren zur Kontrastmaximierung wird in [Kubisch, 1995] beschrieben. Eine Erläuterung der Arbeitsweise dieses Verfahrens findet in Kapitel A.1 statt. Das Grundprinzip liegt darin, daß die Blende auf den Wert eingestellt wird, für den die Varianz des Grauwertistogramms unter allen Einstellungen am größten ist.

Dieses Verfahren wird als Normierungskriterium bei der Aufnahme der Nahtprobestreifen verwendet. Es muß noch bestimmt werden, wie oft und zu welchem Zeitpunkt man es anwendet, um so die Blende auf einen neuen Wert einzustellen.

Diese Entscheidung hängt unter anderem auch von der typischen Situation bei der Nahtbegutachtung ab: In vielen Fällen sieht ein Klassifikationsvorgang so aus, daß mehrere Probennähte einer einheitlichen Stoffart hintereinander klassifiziert werden. Das läßt die Blendeneinstellung nach zwei verschiedenen Vorgehensweisen sinnvoll erscheinen:

1. vor jeder Aufnahme einer neuen Naht oder
2. vor der Aufnahme einer neuen Nahtserie

Für die Handhabung nach Punkt 1 spricht, daß jede Aufnahme auf den größten Kontrast eingestellt wird und somit auch ein Maximum an Information in die Aufnahmen einfließt. Eine unerwünschte Nebenwirkung ist hierbei aber, daß das Verfahren versucht, Grauwertunterschiede im aufzunehmenden Objekt, bei schwach gewellten Stoffen also auch Welligkeiten mit kleiner Amplitude, so darzustellen, daß sie möglichst gut zu erkennen sind. Hierbei bekommen jedoch schwach gewellte Nähte im Vergleich zu stark gewellten Nähten unverhältnismäßig viel Welligkeit zugeschrieben.

Dagegen werden bei einer Blendeneinstellung nach Punkt 2 die verschiedenen Ausprägungen von Welligkeiten korrekter wiedergegeben; hier sind die tatsächlichen und die aufgenommenen Welligkeiten korreliert. Diese Argumente lassen eine Blendeneinstellung nach Vorgehensweise 2 am sinnvollsten erscheinen.

Die Eichung für die verwendete Blende wird mit dem Nahtstreifen der höchsten Welligkeit (Note 1) durchgeführt. Dadurch ist gewährleistet, daß die Lichtintensität des Nahtstreifens nicht die Grenzen des darstellbaren Grauwertbereichs überschreitet.

3.3. Aufnahme der Trainings- und Testbeispiele

Für die Untersuchungen sind vom IFN verschiedene „Serien“ von Nahtproben zur Verfügung gestellt worden. Eine Serie besteht aus einer Anzahl von Stoffproben aus einheitlichem Material und einheitlicher Farbe, die zwischen 15 und 90 Stück beträgt. Jeder Nahtprobe liegt eine Expertenbenotung bei. Insgesamt sind drei dieser Serien verwendet worden. Ein Stoffstreifen besitzt eine Breite von etwa 4–5 cm und eine Länge von 35–60 cm.

Die ersten und die letzten ≈ 10 cm der Länge werden von der Nähfachkraft bei der Notenfindung jedoch nicht berücksichtigt. Der Grund hierfür ist, daß sich die Nähmaschine

3. Bildaufnahme

beim Nähen dieses Abschnittes in einer Beschleunigung befindet, die die Nahtqualität nachhaltig beeinflussen kann.⁴⁵

Während der Aufnahme wird von jedem Probestreifen genau ein Bild angefertigt. Die erforderliche Gesamtlänge von 20 cm (vergleiche (3.1)) kann so zumindest annähernd aus dem „erlaubten“ Streifenausschnitt gewonnen werden, $35 - 2 \cdot 10 = 15$ cm.

Zum Testen der Leistungsfähigkeit des Klassifikationssystems werden die Aufnahmen in zwei Mengen unterteilt: in eine Trainings- und eine Testmenge. Die Trainingsmenge wird dazu benutzt, ein neuronales Netz auf die Struktur der Merkmale, die aus den Aufnahmen extrahiert werden, zu trainieren. Mit den Aufnahmen der Testmenge wird eine Antwort des Netzes auf unbekannte Beispiele abgerufen und anhand des Klassifikationsfehlers die Güte des Verfahrens bestimmt. Die Unterteilung der Beispielmenge in Trainings- und Testmenge ist erforderlich, damit das Netz auf seine Generalisierungsfähigkeit überprüft werden kann. Im allgemeinen werden diejenigen Beispiele, mit denen trainiert wurde, selbst sehr gut von dem Netz in der Abrufphase erkannt. Dies ist in der Praxis natürlich nicht ausreichend. Das Netz soll auch auf nicht bekannte Beispiele generalisieren können.

⁴Laut Aussage von Frau Donath, IFN.

⁵Dies hat sich auch in ersten Untersuchungen, die ohne Kenntnis der Aussage durchgeführt wurden, bestätigt.

4. Bildpositionierung

Ein bedeutendes Kriterium für die Nahtqualität ist, wie in Kapitel 2.5 beschrieben wurde, die Ausprägung einer längs zur Naht verlaufenden Welligkeit. In Abbildung 2.3 kann man zudem erkennen, daß die Stärke und die Frequenz der Welligkeit von der Entfernung zur Nahtmitte abhängig ist. Der Vergleich der Welligkeiten zwischen einzelnen Probenähten erfordert daher eine genaue Positionierungsmöglichkeit von „Wellendetektoren“ bezüglich des Abstands zur Nahtmitte. Allerdings kann die Nahtmitte bei der Aufnahme nicht immer genau in die Mitte des Bildes positioniert werden. Eine Koordinate (x_0, y_0) im Grauwertbild entspricht also nicht bei jeder Aufnahme derselben Position auf dem Probestreifen. Dies ist Anlaß für die Konstruktion eines Bildpositionierers, der die Stoffbilder derart verschieben und drehen soll, daß sich die Nähte anschließend in einer einheitlichen Position befinden. Er wird im folgenden vorgestellt.

An dieser Stelle sei erwähnt, daß der Bildpositionierer auch Stoffaufnahmen transformieren kann, in denen die Naht um 90° verdreht oder auch 40 Pixel verschoben aufgenommen wurden. Jedoch füllt die zurechtgerückte Naht bei der hier gewählten Auflösung dann nur noch einen kleinen Teil des Bildes aus, so daß eine sinnvolle Nahtuntersuchung nicht mehr durchführbar ist. Es wird also angenommen, daß die Stoffe derart aufgenommen wurden, daß die Naht weitestgehend längs und in der Mitte verläuft.

Die Aufgabe des Bildpositionierers teilt sich in zwei Bereiche:

1. das Aufspüren des Nahtverlaufes
2. die Verschiebung/Drehung des Bildes entsprechend 1

Bereich 1 wird mit Hilfe der *Hough Transformation* durchgeführt. Dieses Hilfsmittel, welches die Aufgabe hat, den Nahtverlauf als Gerade zu approximieren, wird im folgenden Abschnitt erklärt, bevor anschließend auf den Nahtdetektions-Algorithmus als Ganzes eingegangen wird. Weitere Literatur zur Hough-Transformation befindet sich in [Davies, 1990] und [Bässmann and Besslich, 1991].

4.1. Hough Transformation

Die Hough-Transformation ist ein allgemeines Hilfsmittel zur Liniendetektion. Dessen Leistung ist es, durch Transformation eines binären Ortsraumes (z.B. ein binäres Kantenbild) in einen „Geradenraum“ Information darüber zu liefern, durch welche Geraden eventuelle Mengen kollinearere Punkte, die im Ortsraum liegen, beschrieben werden können.

4.1.1. Die Hessesche Normalenform als Geradendarstellung

Die Darstellungsform, in der eine Gerade bei der Hough-Transformation am geeignetsten kodiert wird, ist die Normalendarstellung (Hessesche Normalenform). In dieser Beschreibungsform werden die Geradenparameter m und b , welche in der konventionellen Beschreibungsform Steigung und Ordinatenabschnitt bestimmen und gemeinsam mit der Gleichung

$$y = mx + b \tag{4.1}$$

die Punkte $P = (x, y)$, die auf der Geraden liegen, bestimmen, gegen zwei neue Parameter θ und ρ ausgetauscht. θ bezeichnet dabei den Winkel zwischen der x -Achse und

4. Bildpositionierung

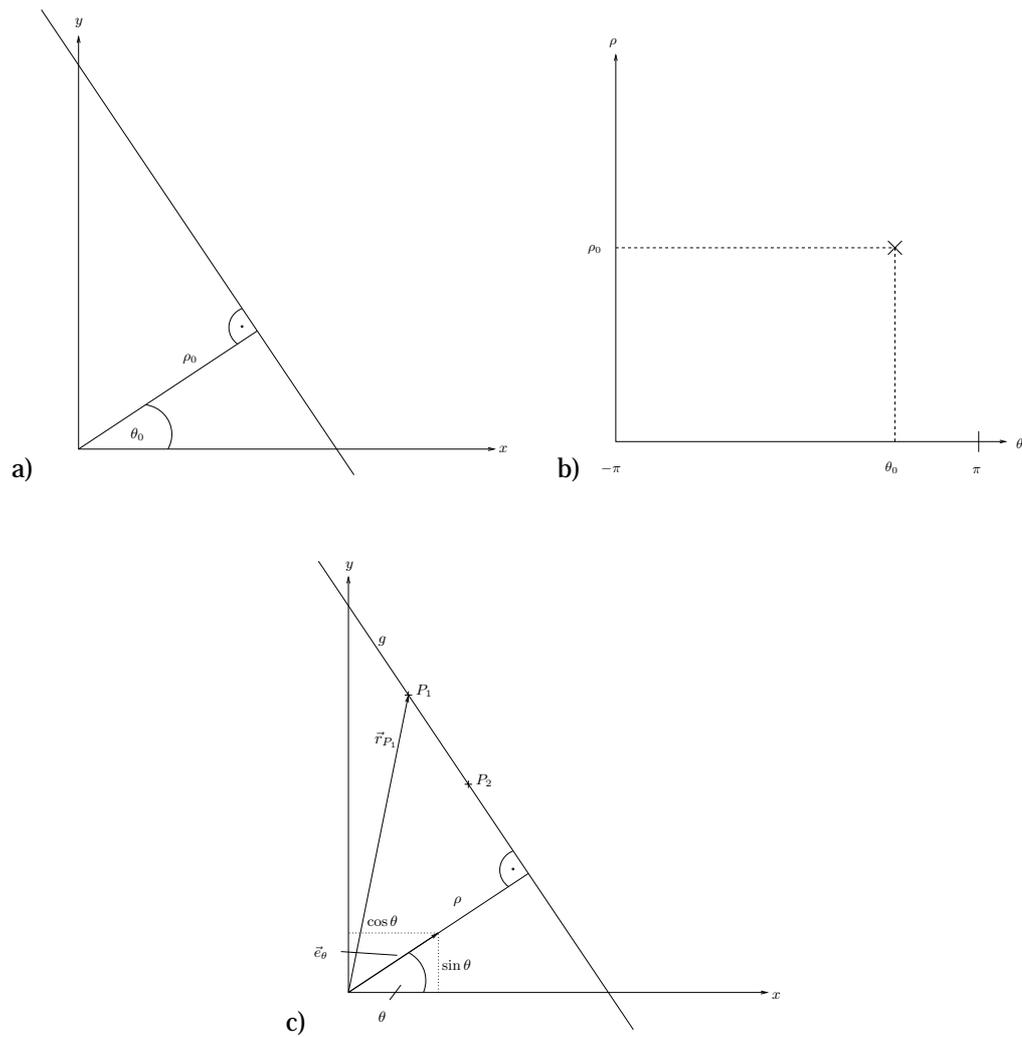


Abbildung 4.1.: Die Parameter θ_0 und ρ_0 der Normalendarstellung einer Geraden g_0 im Ortsraum (a) und im Houghraum H eingezeichnet (b). Abbildung (c) veranschaulicht die Geradengleichung (4.2)

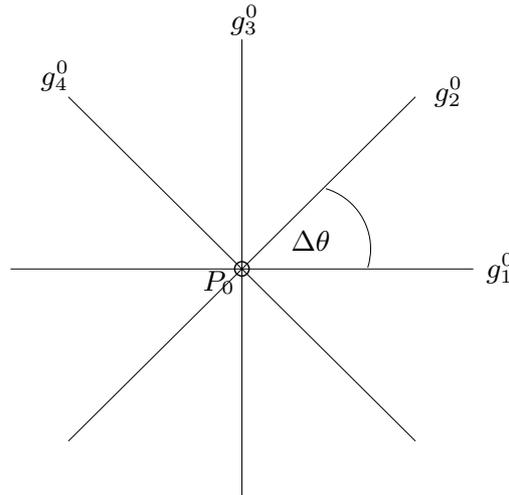


Abbildung 4.2.: Bei der Hough-Transformation wird durch jeden ausgezeichneten Punkt P_i eine Menge von Geraden g_j^i gelegt, hier für $i = 0$. Die Anzahl der Geraden n wird durch den Auflösungswert $\Delta\theta$ bestimmt: $n = \pi/\Delta\theta$.

der Geradennormale; ρ bezeichnet die kürzeste Entfernung vom Ursprung zur Geraden (siehe Abbildung 4.1 a).

Für diese Parameter gilt nun anstatt (4.1) die neue Geradengleichung

$$\rho = x \cos \theta + y \sin \theta \quad (4.2)$$

Gleichung (4.2) ist leicht einzusehen, wenn man sie als Skalarprodukt des Ortsvektors $\vec{r}_P = (x, y)$ und des in Normalenrichtung gerichteten Einheitsvektors $\vec{e}_\theta = (\cos(\theta), \sin(\theta))$ notiert (siehe Abbildung 4.1 c):

$$\rho = \begin{pmatrix} x \\ y \end{pmatrix} \cdot \begin{pmatrix} \cos \theta \\ \sin \theta \end{pmatrix} = \vec{r}_P \cdot \vec{e}_\theta \quad (4.3)$$

$\vec{r}_P \cdot \vec{e}_\theta$ ist nach der Definition des Skalarproduktes die Länge der Projektion von \vec{r}_P auf den Einheitsvektor \vec{e}_θ . Sie ist wegen der Orthogonalität von g und \vec{e}_θ jedoch für alle Punkte P_i der Geraden g gleich und besitzt den Wert ρ . Genau dies ist auch die Aussage von (4.2) und (4.3).

4.1.2. Die Transformation

Die Grundlage der Hough-Transformation bildet die Dualität zwischen Punkt und Gerade [Davies, 1990]. Ein Punkt kann einerseits durch seine Koordinaten definiert werden oder andererseits anhand sich schneidender Geraden. Die Beziehung dieser Dualität zur Liniendetektion wird einleuchtender, wenn man sich eine Menge kollinearere Punkte P_i vorstellt und die Menge der Geraden auflistet, die durch die einzelnen P_i laufen. In dieser Auflistung wird eine Gerade mehrfach auftreten, nämlich diejenige, auf der die Punkte P_i liegen. Alle anderen Geraden sind nur einfach vertreten. Auf diese Weise kann die Gerade ermittelt werden, auf der die Punkte P_i liegen. Selbst wenn einige der Punkte P_i nicht auf der Hauptgeraden liegen, wird sich das Ergebnis nicht ändern. Dies ist auch das Prinzip der Hough-Transformation.

Sie bildet von einem Ortsraum O in einen *Akkumulatorraum* A ab. An der Position $(\theta_0, \rho_0) \in A$ steht die Anzahl der gefundenen Geraden $g_0 = (\theta_0, \rho_0)$, die durch die Punkte P_i laufen.

Dies geschieht auf folgende Weise: Im Ortsraum O gibt es eine Menge ausgezeichneter Punkte P_i . Für den hier behandelten Fall des Bildpositionierers sind dies zum Beispiel die in einer Vorverarbeitung erkannten Kantenpunkte. Durch jeden dieser Punkte P_i werden n Geraden g_j^i gelegt. Die Anzahl n und die Winkel der Geraden θ_j^i bestimmt eine festgelegte Winkelauflösung $\Delta\theta$. Die Anzahl n ergibt sich zu $n = \pi/\Delta\theta$ (siehe Abbildung 4.2).

4. Bildpositionierung

Der zweite Geradenparameter $\tilde{\rho}_j^i$ wird für jede Gerade mithilfe (4.2) berechnet und auf einen Wert ρ_j^i diskretisiert. Für die jeweils errechnete Gerade (θ_j^i, ρ_j^i) wird im Houghraum der Akkumulator nun um 1 erhöht.

Auf diese Weise erhalten natürlich sehr viele Geraden $(\theta_j^i, \rho_j^i) \in H$ einen Eintrag, jedoch wird eine Gerade $g_0 = (\theta_0, \rho_0)$, auf der mehrere Punkte liegen, bei jedem Treffer inkrementiert. Dadurch bekommt die Gerade $g_s = (\theta_s, \rho_s)$, welche die meisten Punkte P_i auf sich vereint, auch den höchsten Wert im Houghraum H zugeschrieben.

Für eine Liniendetektion kann man nun den Houghraum bezüglich der problemspezifischen Fragestellung auswerten. Im Falle des Nahtdetektors wird das Argument-Maximum der Houghtransformierten ausgewertet und als „Nahtgerade“ interpretiert.

4.2. Nahtdetektor

Die Nahtdetektion wird in zwei Schritte unterteilt. Ein erster Schritt berechnet aus dem Originalbild ein binäres Kantenbild. Dies ist durch einen Filtervorgang mit einem 5x5-Laplace-Operator und anschließender Schwellwertberechnung implementiert.

Abbildung 4.3 b) zeigt das Ergebnis dieser Filteroperation für eine Beispielnah. Es fällt auf, daß sich neben den erkannten Nahtpunkten in diesem Bild auch Kantenpunkte befinden, die durch die Gewebewelligkeit oder durch einfaches Rauschen erzeugt wurden. Trotzdem ist der Verlauf der Naht deutlich zu erkennen, weil die erkannten Kantenpunkte sich im Nahtbereich häufen.

An dieser Stelle setzt nun die Hough-Transformation, der zweite Schritt der Nahtdetektion, an. Mit ihrer Hilfe wird die Gerade $g_0 = (\theta_0, \rho_0)$ bestimmt, auf der die meisten Punkte im Kantenbild liegen, nämlich durch Berechnung des Argument-Maximum der Houghtransformierten h (siehe Kapitel 4.1).

$$g_0 = \operatorname{argmax}(h(\theta, \rho))$$

An dieser Stelle wird angenommen, daß die größte Menge kollinearere Punkte, die der Kantendetektor gefunden hat, auf der Naht liegt; und daher gilt für die Nahtgerade g_{Naht} :

$$g_{\text{Naht}} = g_0$$

Abbildung 4.4 zeigt in Teil c) die Houghtransformierte des Kantenbildes aus b) als Helligkeitsbild. Hierin ist ein großer Peak an der Stelle der „Nahtgeraden“ zu erkennen. Diese Gerade, in d) ins Kantenbild eingezeichnet, approximiert die Naht sehr genau.

Insgesamt arbeitet das Verfahren sehr verlässlich. Bei den verwendeten Probenähten hat es sogar in 100% der Fälle eine Gerade ermittelt, die zumindest teilweise auf der Naht liegt. „Teilweise“ bedeutet, daß in einigen Fällen der Probestreifen einen krummen Nahtverlauf aufwies, der natürlich nicht vollständig von einer Geraden approximiert werden kann.

4.3. Bildverschiebung

Nun muß das Bild noch in die richtige Position gebracht werden. Die Kodierung, die die Hough-Transformation verwendet, kommt dieser Aufgabe entgegen: zur Beschreibung der Geraden g wird die Hessesche Normalform benutzt. Diese wird durch zwei Parameter θ und ρ definiert. θ bezeichnet den Winkel zwischen der x -Achse und der Geradennormale und ρ die kürzeste Entfernung vom Ursprung zur Gerade (siehe Kapitel 4.1).

Die Positionierung besteht nun aus zwei Teilen:

1. einer Translation in x -Richtung um eine Strecke s
2. einer Rotation um den Bildmittelpunkt $M = (\frac{X}{2}, \frac{Y}{2})$ um einen Winkel φ

Der Translationsparameter s läßt sich mit den aus der geometrischen Anordnung (Abbildung 4.4) erhaltenen Beziehungen

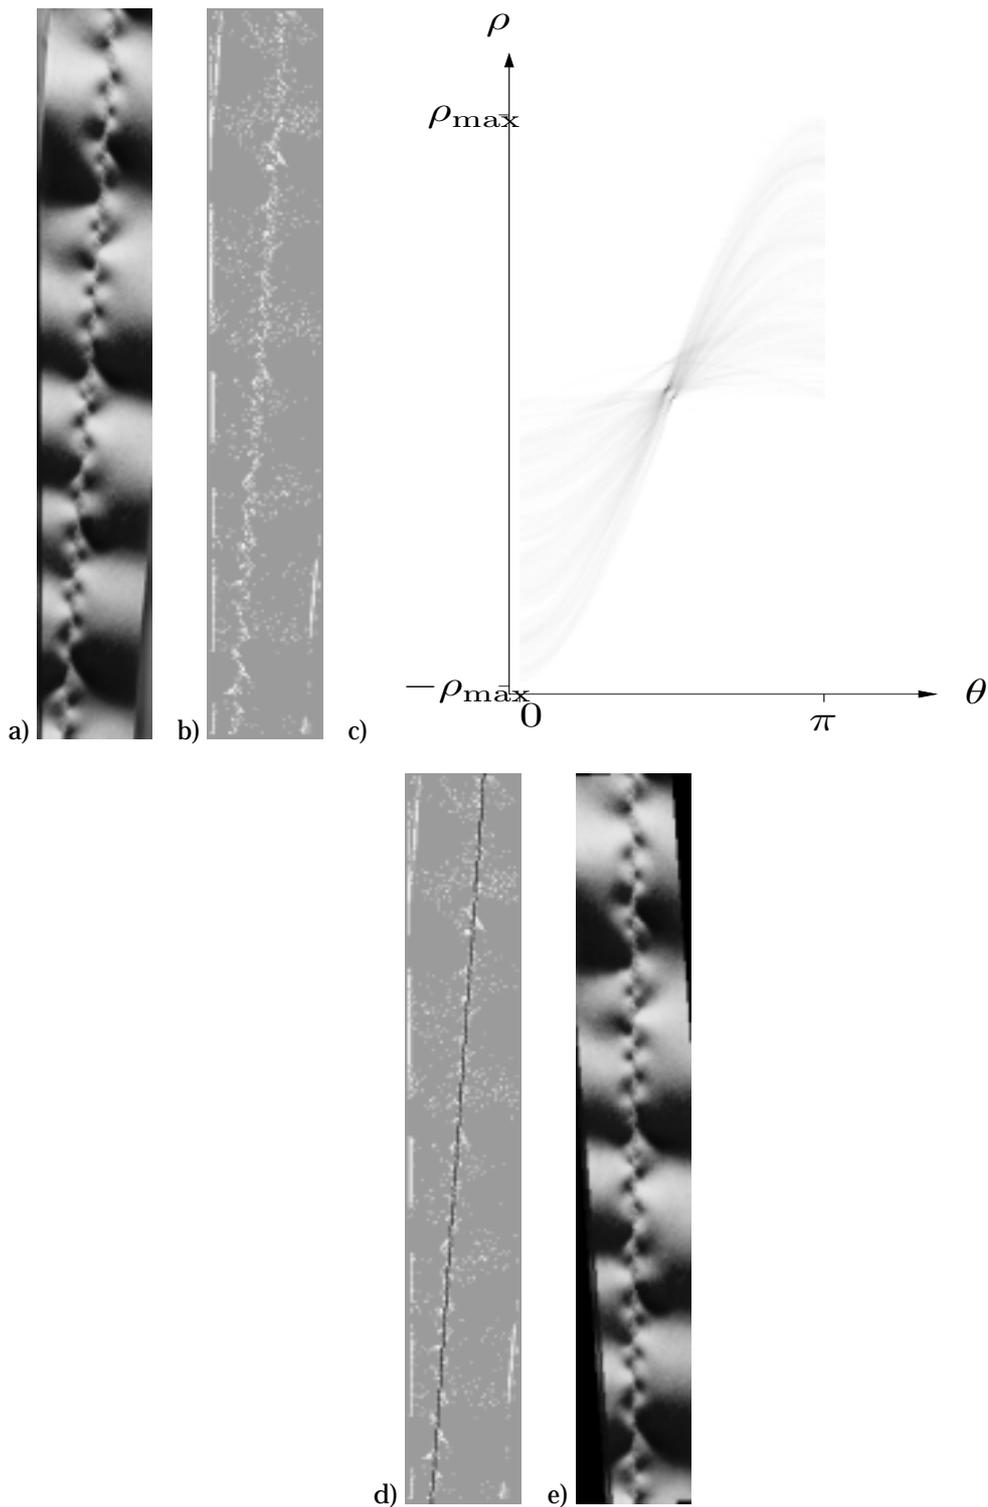


Abbildung 4.3.: Vorgehensweise bei der Nahtdetektion: Aus dem Originalbild (a) wird zunächst ein Kantenbild (b) erstellt. Das Kantenbild wird in den Houghraum transformiert (c). Dort können die Parameter derjenigen Gerade (θ_0, ρ_0) entnommen werden, auf der die meisten Kantenpunkte liegen. Diese Gerade wird als Nahtgerade interpretiert und ist in d) ins Kantenbild eingezeichnet. Gemäß der Parameter θ_0 und ρ_0 wird das Originalbild schließlich gedreht und verschoben (e). Die großflächigen schwarzen Stellen links unten und rechts oben in (e) stammen davon, daß durch die Aufnahmebreite von 80 Pixeln der Bildrand abgeschnitten wurde und deshalb nichtdefinierte Positionen in das Bild verschoben werden.

4. Bildpositionierung

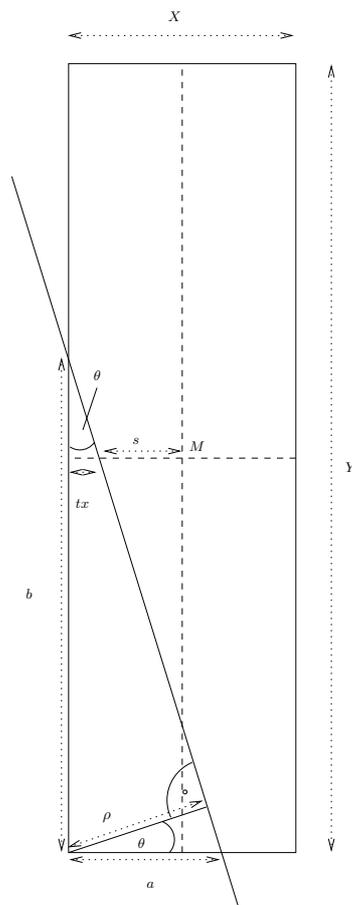


Abbildung 4.4.: Die Berechnung der Verschiebungswerte (ϕ, s) aus den Geradenparametern (θ, ρ)

$$a = \frac{\rho}{\cos \theta}$$

$$b = \frac{\rho}{\sin \theta}$$

$$\frac{a}{tx} = \frac{b}{b - Y/2} \quad (\text{Strahlensatz})$$

errechnen zu

$$s = X/2 - tx \quad (4.4)$$

$$tx = \begin{cases} \rho & , \text{ falls } \theta = 0 \\ \frac{a(b - \frac{Y}{2})}{b} & , \text{ sonst} \end{cases}$$

X und Y bezeichnen die Bildbreite bzw. -höhe. Die undefiniertheit für den Wert $\theta = \pi/2$ soll hier nicht weiter stören, da dies einer Aufnahme mit waagerechter Naht entspräche. Dieser Zustand sollte, wie es bereits am Anfang dieses Kapitels erwähnt wurde, schon bei der Aufnahme vermieden werden.

Nach der Translation verläuft die Naht also genau durch den Bildmittelpunkt und braucht nur noch mit dem Winkel φ um den Bildmittelpunkt gedreht werden, damit es sich mit der vertikalen Bildhalbierenden deckt. Die Gleichung für diese Rotation lautet:

$$\begin{pmatrix} x' \\ y' \end{pmatrix} = \begin{pmatrix} X/2 \\ Y/2 \end{pmatrix} + \begin{pmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{pmatrix} \begin{pmatrix} x - X/2 \\ y - Y/2 \end{pmatrix}$$

Sie setzt sich zusammen aus (i) einer Translation des Bildmittelpunktes M in den Ursprung, (ii) einer Rotation im Ursprung um den Winkel φ und (iii) einer Rücktranslation des gedrehten Bildes in den Bildmittelpunkt.

Der Rotationsparameter φ ist gleich dem Wert des Winkels θ der Geradengleichung (siehe Abbildung 4.3)

$$\varphi = \theta \quad (4.5)$$

womit die Positionierungsparameter s und φ durch die Gleichungen (4.4) und (4.5) vollständig gegeben sind.

Damit ist die Implementierung des Bildpositionierers fertiggestellt. Die Welligkeiten können so in Abhängigkeit zur Entfernung zur Naht berechnet werden. Davon wird im folgenden Kapitel reger Gebrauch gemacht werden.

5. Das Neuronale Netz

5.1. Neuronale Netze zur Repräsentation des Merkmalsraumes

Neuronal motivierte Algorithmen haben sich in der jüngsten Vergangenheit mit ihrer Fähigkeit, hochdimensionale Bilddaten in einer kompakten Weise zu repräsentieren, oft als ein geeigneter Ansatz für ein optisches Klassifikationsproblem bewährt. Auch in dieser Arbeit bilden sie die Grundlage zur Implementation des Klassifikators.

Dieses Kapitel erklärt den Typ eines neuronalen Netzes, welches in dieser Arbeit verwendet wird, die *Kohonenkarte*. Sie ist 1984 von Teuvo Kohonen entwickelt worden [Kohonen, 1984] und gehört zur Klasse der selbstorganisierenden Merkmalskarten. Umfassende Literatur zur Kohonenkarte befindet sich u.a. in [Ritter et al., 1992].

Die Kohonenkarte erscheint deshalb für den in dieser Arbeit behandelten Nahtklassifikator geeignet, weil es bei ihr möglich ist, den Lernvorgang in hochdimensionalen Merkmalsräumen, zumindest teilweise, zu visualisieren. Dadurch wird die Möglichkeit geschaffen, Unzulänglichkeiten aufzuspüren und eventuell zu verbessern.

5.2. Die Kohonenkarte

Die Eigenschaft der Kohonenkarte besteht darin, einen n -dimensionalen (Eingabe-) Vektorraum V auf ein m -dimensionales diskretes Gitter A abzubilden. Es stellt also eine Abbildung ϕ dar:

$$\phi : V \mapsto A \tag{5.1}$$

Im allgemeinen ist dabei $m \leq n$. Als Gitterdimension m wird oft $m = 2$ gewählt. Bei der Abbildung—und dies ist eine nützliche Stärke des Kohonen-Modells—bleiben die Nachbarschaftsbeziehungen aus V in A im Idealfall bestmöglich erhalten. „Bestmöglich“ bedeutet, daß prinzipielle Dimensionskonflikte (die auftreten, wenn man z.B. $n = 3$ auf $m = 2$ Dimensionen abbilden möchte) zwar nicht aufgelöst werden (können), darüber hinaus das Netz jedoch versucht, die Topologie aus V in A zu erhalten.

Eine Dimensionsreduzierung, die auftritt, wenn man $m < n$ wählt, macht man sich zunutze, um eventuelle redundante Informationen in V zu eliminieren oder auch, um einen hochdimensionalen Merkmalsraum zu visualisieren. Abbildung 5.1 zeigt das Prinzip der Kohonenkarte, hier für den Fall $m = 2$: Die Kohonenabbildung ϕ bildet vom Stimulusraum V auf das Gitter A so ab, daß den benachbarten Vektoren $\vec{v}, \vec{v}' \in V$ möglichst auch benachbarte Gitterpunkte $s, s' \in A$ zugeordnet werden.

Bevor darauf eingegangen wird, wie sich die innere Struktur des Kohonennetzes bildet, also wie die Lernregel beim Kohonenalgorithmus aufgebaut ist, soll zunächst die Abbildungsfunktion ϕ , die die Antwort des Netzes auf ein Muster regelt, motiviert werden.

Jeder Gitterpunkt im (in diesem Fall 2-dimensionalen) Gitter $(i, j) \in A$ repräsentiert ein formales Neuron und besitzt einen „Gewichtsvektor“ $\vec{w}_{ij} \in V$. Der Vektor \vec{w}_{ij} (der sich während des Lernvorgangs entwickelt hat) ist Mittelpunkt des Rezeptiven Feldes in V für das Neuron (i, j) . Auf diese Weise wird V in sogenannte *Tesselationszellen* aufgeteilt, wobei jede Tesselationszelle einen Repräsentanten (i, j) in A hat. In Abbildung 5.1 ist z.B. s das verantwortliche Neuron für die linke obere Tesselationszelle und w_s dessen Gewichtsvektor.

Eine weitere graphische Veranschaulichung erhält man, wenn man die Neuronen s an den Koordinaten ihres Gewichtsvektors \vec{w}_s in den Stimulusraum V einträgt und benachbarte (hier ist benachbart bzgl. der Gitterposition gemeint) Neuronen verbindet (siehe

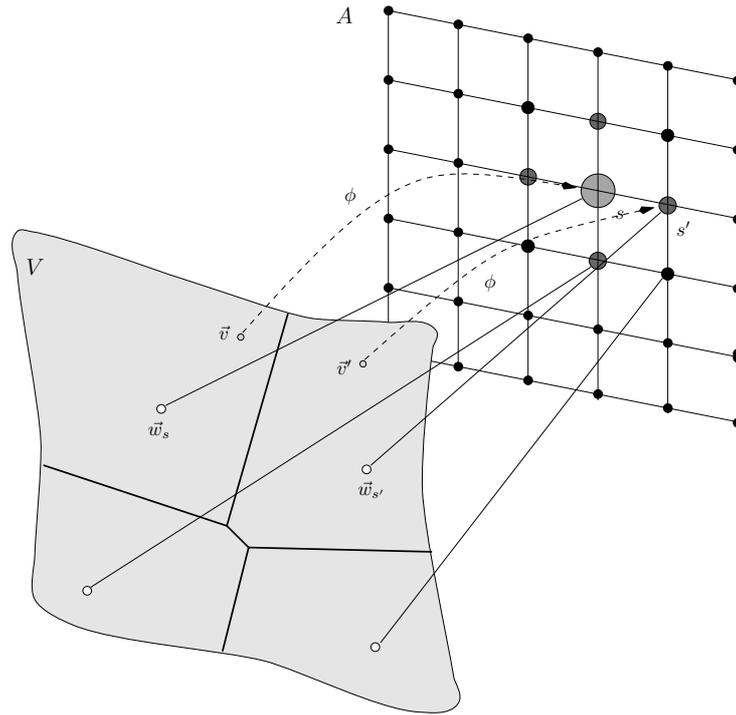


Abbildung 5.1.: Das Prinzip einer Kohonenkarte: Die Abbildung ϕ eines Kohonennetzes bildet nachbarschaftserhaltend ab: Den benachbarten Vektoren $\vec{v}, \vec{v}' \in V$ werden durch ϕ möglichst auch benachbarte Gitterpunkte $s, s' \in A$ zugeordnet. Im Stimulusraum V erkennt man die Einteilung in Tesselationszellen.

Abbildung 5.2). In einer guten Nachbarschaftserhaltung würde sich das Neuronengitter hierbei „glatt“ in den Stimulusraum V hineinlegen.

Die Unterteilung des Stimulusraumes in Tesselationszellen führt nun zu folgender Definition von ϕ :

$$s = \phi(\vec{v}) = \operatorname{argmin}_{r \in A} d(\vec{w}_r, \vec{v}) \quad (5.2)$$

d ist dabei eine frei wählbare Abstandsfunktion. Der Abbildungswert $\phi(\vec{v})$ ist also dasjenige Neuron s , dessen Gewichtsvektor \vec{w}_s unter d am nächsten zu \vec{v} liegt.

Als Abstandsfunktion d wird oft der euklidische Abstand

$$d(\vec{x}, \vec{y}) = \|\vec{x} - \vec{y}\| \quad (5.3)$$

gewählt.

Bis hier ist also die Abbildungsfunktion ϕ beschrieben worden, mit deren Hilfe die Antwort des Netzes auf einen Stimulus \vec{v} ermittelt wird. Im folgenden wird die Lernregel für den Kohonen-Algorithmus beschrieben.

Ausgangspunkt für einen Lernschritt ist das Eintreffen eines „Reizes“ bzw. Trainingsbeispiels \vec{v}_0 . Von hier an läuft der Adaptionsvorgang in zwei Schritten ab. Im 1. Schritt wird gemäß der Abbildungsfunktion (5.2) dasjenige Neuron s bestimmt, in dessen Tesselationszelle der Reiz \vec{v}_0 fällt

$$s = \phi(\vec{v}_0)$$

Im 2. Schritt wird für jeden Gewichtsvektor \vec{w}_r in Abhängigkeit vom (Gitter-) Abstand zum Siegerneuron s , das auch Erregungszentrum genannt wird, ein Lernschritt ausgeführt:

$$\Delta \vec{w}_r = \epsilon h_{rs} (\vec{v}_0 - \vec{w}_r), \quad \forall r \in A \quad (5.4)$$

Die Größe des Lernschritts hängt von der Schrittweite ϵ und von der Erregungsfunktion h_{rs} . Dies ist eine Funktion abhängig vom Abstand $a = \|r - s\|$, $h_{rs} = h_{\|r-s\|}$, die ihr

5. Das Neuronale Netz

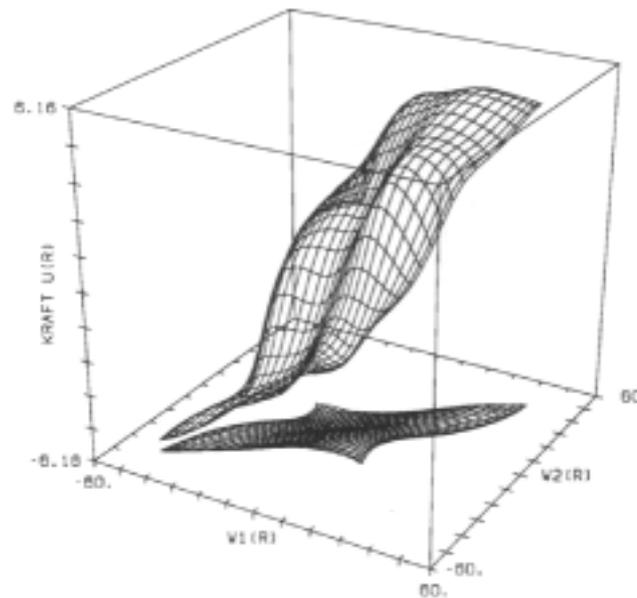


Abbildung 5.2.: Die Lage des Kohonennetzes im Stimulusraum: In dieser Darstellung ist jedes Neuron (i, j) an den Koordinaten \vec{w}_{ij} ihres Gewichtsvektors im Stimulusraum eingetragen. Im Gitter benachbarte Neuronen sind verbunden worden. In diesem Beispiel kann man erkennen, wie das Netz im Sinne einer Dimensionsreduktion den 3-dimensionalen Stimulusraum mit dem 2-dimensionalen Gitter „glatt“ ausfüllt. Dieses Schaubild ist aus einer Anwendung entnommen, in der ein Kohonennetz zur Lösung des „Stabbalance-Problems“ herangezogen wurde. (aus [Ritter et al., 1992])

Maximum für den Wert $a = \|r - s\| = 0$ annimmt und für größere Werte von $a = \|r - s\|$ symmetrisch abnimmt. Diese Eigenschaft von h korrespondiert zu der Tatsache, daß das Erregungszentrum innerhalb dieses Lernschritts am stärksten lernt. Gewöhnlich wird für die Erregungsfunktion h eine Gaußfunktion

$$h_{rs} = \exp\left(-\frac{(r - s)^2}{\sigma^2}\right) \quad (5.5)$$

verwendet.

Der Term $\epsilon(\vec{v}_0 - \vec{w}_r)$ aus der Lernregel 5.4 gibt die Richtung des Lernvorgangs an: Geometrisch ist der Vektor $\vec{v}_0 - \vec{w}_r$ der Vektor, der vom lernenden Neuron r (bzw. dessen Gewichtsvektor \vec{w}_r) zum Stimulus zeigt. Das Neuron wird somit einen Schritt weiter zum Stimulus hingezogen (siehe Abbildung 5.3).

In einer anderen Interpretation kann man (5.4) mit der Hebbschen und Antihebbschen Lernregel deuten. Diese sagt aus, daß der Lern- bzw. Entlernprozeß proportional bzw. negativ proportional zum Produkt von Stimulus und Erregung verläuft. Mit dieser Deutungsweise wird in (5.4) das neue Beispiel v_0 dazugelernt (durch den Term $\epsilon\vec{v}_0 h_{rs}$) und die bisherige Gewichtseinstellung \vec{w}_r entlernt (durch den Term $-\epsilon\vec{w}_r h_{rs}$).

5.3. Das verwendete Kohonennetz

5.3.1. Das Kohonennetz als Klassifikator

In der bisher beschriebenen Form kann der Kohonenalgorithmus „nur“ eine topologieerhaltende Karte erstellen. Es ist noch nicht geklärt, wie er eine Klassifikationsaufgabe löst. Eine Möglichkeit besteht darin, jedem Neuron r_i eine Klasse i zuzuordnen und den Index j des Siegerneurons $s = r_j$ als Ergebnisklasse auszugeben.

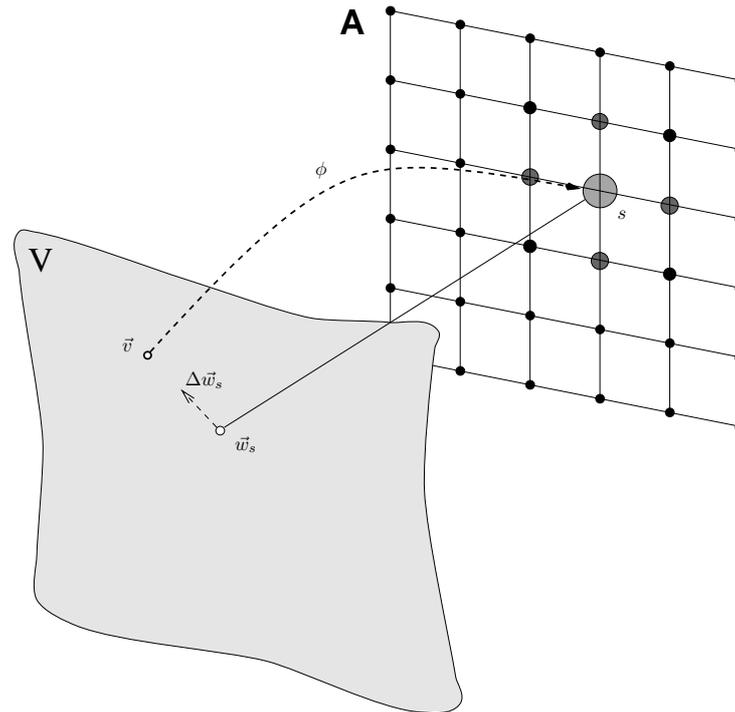


Abbildung 5.3.: Die Lernregel des Kohonenalgorithmus: der Gewichtsvektor des Siegerneuron \vec{w}_s wird hier durch die Lernregel $\Delta \vec{w}_s = \epsilon h_{ss}(\vec{v} - \vec{w}_s)$ zum präsentierten Reiz v hinbewegt.

In dieser Arbeit wird jedoch eine andere Strategie verfolgt: Bei dem behandelten Fall der Nahtklassifikation ist es sinnvoll, nicht nur die absoluten Notenklassen 1,2,3,4 und 5 als Antwort zuzulassen, sondern auch eventuelle Notentendenzen wie etwa durch die Note „2.5“ zu berücksichtigen. Deshalb ist bei der Implementierung des Klassifikators ein kontinuierlicher Wertebereich für die Noten erwünscht.¹

Mit dieser Forderung an den Wertebereich verallgemeinert sich die Klassifikationsaufgabe zu der Adaption einer reellargumentigen und -wertigen Funktion, die im allgemeinen folgende Form besitzt:

$$\kappa : M \mapsto K \quad (5.6)$$

$M = \mathfrak{R}^m$ repräsentiert den m -dimensionalen Eingabe- und $K = \mathfrak{R}^k$ einen k -dimensionalen Ergebnisraum. Die Wahl der Bezeichner M und K läßt hier schon die spätere Verwendung von M als Merkmalsraum und K als „Klassenraum“ erahnen.

Die Abbildung κ (5.6) wird mit einem Kohonennetz folgendermaßen realisiert (siehe Abbildung 5.4): M und K werden zu einem kombinierten Eingaberaum

$$V = M \times K$$

zusammengefaßt. Das Kohonennetz wird darauf nach den Regeln aus Kapitel 5.2 auf den kombinierten Raum V trainiert. Es werden dem Netz also Trainingsbeispiele $\vec{v}_i = (\vec{m}_i, \vec{k}_i) \in V$, ($\vec{m}_i \in M$, $\vec{k}_i \in K$) präsentiert, nach denen sich die Struktur der Kohonenkarte bilden soll. Die Struktur sieht nach abgeschlossenem Trainingsvorgang idealerweise so aus, daß zusammengehörige Bereiche aus Merkmalen $\vec{M} \subset M$ und Klassen $\vec{K} \subset K$ zusammen eine gemeinsame Tesselationszelle bilden oder zumindest Tesselationszellen-Nachbarn sind.

Der Trainingsvorgang hat sich im Vergleich zu Kapitel 5.2 nicht wesentlich geändert. Dahingegen muß die Abstandsfunktion (5.3) der Abruffunktion (5.2) etwas variiert wer-

¹Strenggenommen stellt dies keine Klassifikation im mathematischen Sinne dar, da eine solche in eine diskrete Klassenmenge abbildet. In diesem Fall ist die Klassenmenge dagegen kontinuierlich. Der hier vorgenommene Vorgang einer Notengebung besitzt jedoch intuitiv trotzdem einen Klassifikationscharakter und daher soll im folgenden weiterhin von einer „Klassifikation“ gesprochen werden.

5. Das Neuronale Netz

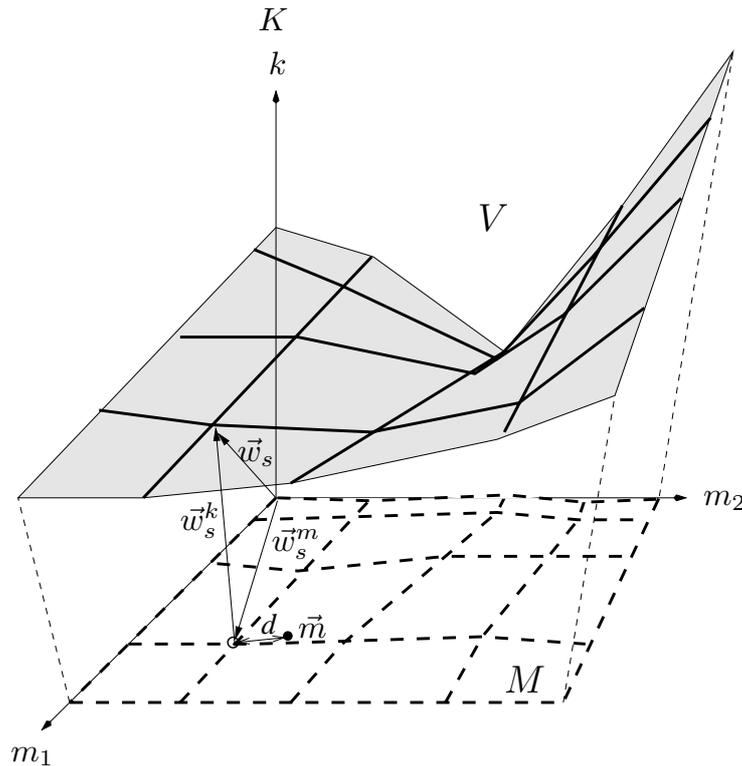


Abbildung 5.4.: Die Klassifikation mit einem Kohonennetz: Es wird der Gewichtsvektor \vec{w}_s des Neurons bestimmt, welches im V -Unterraum $M \subset V$ am nächsten zum Stimulus \vec{m} liegt. Das Ergebnis ist dann gegeben durch den „Klassenwert“ von \vec{w}_s, \vec{w}_s^k .

den. Die Situation beim Abruf ist, daß ein Merkmal $\vec{m} \in M$ vorliegt und die dazugehörige Klasse $\vec{k} \in K$ vom Netz erfragt werden soll. Somit ist der Stimulusvektor $\vec{v} = (\vec{m}, \vec{k})$ unvollständig und die Abbildung ϕ (5.2) im Prinzip nicht definiert.

Dieser Konflikt wird nun dadurch gelöst, daß die Abstandsfunktion d (5.3) so gewählt wird, daß der Klassenvektor \vec{k} zur Bestimmung des Siegerneurons unerheblich wird

$$d(\vec{x}, \vec{y}) = \sqrt{\sum_j g_j^2 (x_j - y_j)^2} \quad (5.7)$$

$$g_1, \dots, g_m = 1$$

$$g_{m+1}, \dots, g_{m+k} = 0$$

Durch diese Wahl der g_i geht \vec{k} in die Abstandsberechnung nicht mit ein. Das Siegerneuron s wird also nur anhand des Merkmalsvektors \vec{m} bestimmt.

Wenn das Netz während des vorherigen Lernvorgangs die Struktur des Merkmal-Klassenraumes gut adaptiert hat, dann steht in dem Klassenanteil $\vec{w}_s^k = ((\vec{w}_s)_{m+1}, \dots, (\vec{w}_s)_{m+k})$ von \vec{w}_s (dem Gewichtsvektor des Siegerneurons) die mit dem Merkmalsteil $\vec{w}_s^m = ((\vec{w}_s)_1, \dots, (\vec{w}_s)_m)$ assoziierte Klasse. Damit hat das Netz die Antwort auf die Anfrage \vec{m} gefunden:

$$\kappa(\vec{m}) = \vec{w}_s^k$$

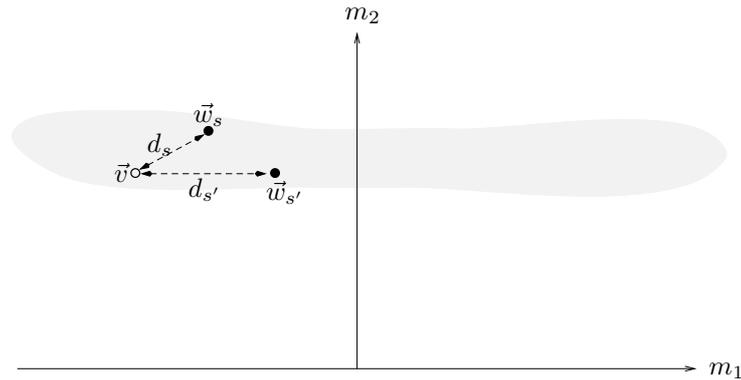


Abbildung 5.5.: 2-dimensionaler Merkmalsraum, in dem die beiden Merkmale m_1 und m_2 unterschiedlich große Varianzen aufweisen (die Verteilung wird durch die flache „Wolke“ beschrieben). Dadurch spiegelt die euklidische Abstandsfunktion d nicht mehr den wahren Abstand unter den Merkmalen wieder. Obwohl der Stimulus \vec{v} bezüglich der Merkmale ähnlicher zum Gewichtsvektor $\vec{w}_{s'}$ ist, berechnet das Netz den minimalen Abstand d_{\min} zu d_s .

5.3.2. Berücksichtigung unterschiedlicher Varianzen in den Merkmalen

An dieser Stelle wird erläutert, wie beim Kohonenalgorithmus zu verfahren ist, wenn unter den Merkmalen eine unterschiedliche Varianz auftritt. Das Problem, welches in diesem Fall entsteht, ist in [Abbildung 5.5](#) illustriert: Für Merkmale mit einer hohen Varianz (in diesem Fall m_1) erstrecken sich die Trainingsbeispiele über einen größeren Bereich. Dadurch sind die Abstände zwischen zwei Vektoren in m_1 -Richtung im allgemeinen größer als in den Richtungen kleiner Varianz (m_2 -Richtung). Bei der Berechnung des Gesamtabstands d kommt m_1 deshalb eine größere Bedeutung zu. Dies ist im allgemeinen nicht erwünscht.

Um ein „gerechtes“ Abstandsmaß zu bekommen, normiert man ähnlich wie bei [\(5.7\)](#) die Abstandsfunktion mit der entsprechenden Varianz:

$$d(\vec{x}, \vec{y}) = \sqrt{\sum_j g_j^2 (x_j - y_j)^2} \quad (5.8)$$

$$g_i = \frac{1}{\sigma_i^2} \quad (5.9)$$

σ_i^2 ist dabei die Varianz des Merkmals i (\neq dem Nachbarschaftsradius σ !). Die Normierung hat zur Folge, daß beim Beispiel aus [Abbildung 5.5](#) bei einer Beibehaltung der geometrischen Abstandsinterpretation die Merkmalswolke in m_1 -Richtung zusammengedrückt und dabei $\vec{w}_{s'}$ näher an den Stimulus \vec{v} herangeschoben wird.

5.3.3. Die Einstellung der Netzparameter

Die in diesem Kapitel beschriebenen Gleichungen für den Lern- und Abrufalgorithmus des Kohonennetzes enthalten Parameter, die für einen Gebrauch des Netzes noch mit definierten Werten belegt werden müssen. Dies sind:

1. die Gitterdimensionalität und -größe A
2. die Lernschrittweite ϵ ([Gleichung 5.4](#))
3. der Nachbarschaftsradius σ der Aktivierungsfunktion h ([Gleichung 5.5](#))
4. die Anzahl n der Trainingsschritte, mit der mit ([Gleichung 5.4](#)) adaptiert wird.

Die Belegung dieser Größen ist folgendermaßen vorgenommen worden:

5. Das Neuronale Netz

Netzparameter	Wert
A	$5 \times 1, 10 \times 1, 25 \times 1, 100 \times 1, 3 \times 3, 5 \times 2, 5 \times 5, 10 \times 10$
ϵ	$0.8 \rightarrow 0.1$
σ	$\frac{1}{3}A_x \rightarrow \frac{1}{10}A_x$
n	$30A_xA_y$

Tabelle 5.1.: Einstellungen für die Netzparameter

1. Eine erfolversprechende Wahl der Gitterdimensionalität ist von vornherein nicht sicher zu bestimmen. Für eine 1-dimensionale Kette spricht die ebenfalls 1-dimensionale Struktur des Ergebnisraums der Klassifikation (die Noten sind linear angeordnet). Jedoch könnte eine zweite Dimension hilfreich sein, um unterschiedliche Gewebematerialien zu beschreiben. Es werden daher beide Dimensionsgrößen getestet und die Ergebnisse verglichen.

Die Gittergrößen werden dabei eingestellt zu:

1-dim Kette: $5 \times 1, 10 \times 1, 25 \times 1, 100 \times 1$

2-dim Gitter: $3 \times 3, 5 \times 2, 5 \times 5, 10 \times 10$

2. Die Lernschrittweite ϵ wird exponentiell mit der Anzahl der Lernschritte verringert. Der Anfangswert ist $\epsilon_a = 0.8$, der Endwert $\epsilon_e = 0.1$.
3. Den Nachbarschaftsradius σ läßt man ebenfalls exponentiell abnehmen. Der Anfangswert σ_a wird auf $1/3$ der Gitterbreite A_x (bei einem 5×1 -Gitter z.B. ist $A_x = 5$) gesetzt, der Endwert σ_e auf $1/10 A_x$.
4. Die Anzahl n der Trainingsschritte wird proportional zur Knotenanzahl $A_x \cdot A_y$

$$n = aA_xA_y$$

gewählt. Dies ist insofern sinnvoll, als daß bei einer größeren Anzahl von Gitterneuronen das einzelne Neuron seltener zum Siegerneuron bestimmt wird. Der Proportionalitätsfaktor a wird zu $a = 30$ gewählt.

Tabelle 5.1 faßt die vorgenommenen Einstellungen noch einmal zusammen.

6. Merkmalsextraktion

Bisher sind Aufnahmen von den Probenähten angefertigt (Kapitel 3) und anschließend bezüglich der Position normiert (Kapitel 4) worden. Sie können *im Prinzip* benutzt werden, um das neuronale Netz (Kapitel 5) ohne eine weitere Datenaufbereitung auf die Zusammenhänge zwischen Naht und Notenklasse zu trainieren. Dies würde derart realisiert werden, daß die Grauwerte und die Notenklassen der Probenähte als Eingabe an das Kohonennetz angelegt werden und das Netz die Struktur dieses Eingaberaumes erlernen soll.

Diese Lösung ist jedoch nicht praktikabel, da die Grauwerte den Eingaberaum sehr hochdimensional gestalten. In dem vorliegenden Fall der Auflösung (Gleichung (3.2)) sind dies $80 \cdot 512 = 40960$ Dimensionen. Zur Adaption von Strukturen in einem Vektorraum dieser Dimensionalität müßte mit einer solch großen Anzahl von Trainingsbeispielen trainiert werden, die bei den Nahtaufnahmen nicht annähernd zur Verfügung steht.

In den Grauwertbildern der Naht ist jedoch einerseits ein hohes Maß an Redundanz als auch andererseits Information enthalten, die mit den Notenklassen nicht korreliert ist. Zu einer Reduktion der Netzeingabedimension muß die wesentliche Information aus der hochdimensionalen Bildinformation herausgelöst werden. Dies ist das Ziel der *Merkmalsextraktion*, bei der aus den Bildern für die Klassifikation relevante Merkmale berechnet und in einen *Merkmalsvektor* abgelegt werden.

In diesem Kapitel wird diskutiert, welche Möglichkeiten sich bei der Generierung von Merkmalsvektoren in der Textilnahtklassifikation anbieten, und wie gut ein auf den gewählten Merkmalen aufbauendes neuronales Netz die Klassifikation jeweils löst.

6.1. Vorgehensweise bei der Beurteilung der Merkmale

Bevor eine erste Auswahl von Merkmalen getroffen wird, soll in diesem Abschnitt skizziert werden, anhand welcher Kriterien eine Beurteilung der Merkmale und ihrer Klassifikationsleistungen stattfindet.

Für alle Merkmale, deren Definition in Kapitel 6.2.2 erfolgen wird, wird eine Reihe von *Probeklassifikationen* unter Verwendung eines Kohonennetzes durchgeführt. Dabei wird bei jeder dieser Probeklassifikationen eine unterschiedliche Geometrie des Kohonengitters zugrunde gelegt. Jede mögliche Kombination von Merkmal und Gittergeometrie stellt einen *Klassifikator* dar.

Das Ziel der Probeklassifikationen ist,

- die Leistungsfähigkeit der einzelnen Klassifikationsmerkmale zu beurteilen und
- eine geeignete Gittergeometrie für das Kohonennetz zu bestimmen.

Die Parametereinstellungen des Kohonennetzes sind in Kapitel 5.3.3 beschrieben.

Die Trainings- und die Testmenge sind zwei disjunkte Mengen von Nahtbildern, die sich jeweils aus 7 Aufnahmen eines schwarzen Woll-Stoffes, 9 Aufnahmen eines roten Nylon-Stoffes und 39 Aufnahmen eines rosa Baumwoll-Stoffes zusammensetzen. Dies ergibt eine Gesamtanzahl von jeweils 55 Trainings- und Testbeispielen.

Die Nahtaufnahmen der Trainingsmenge werden zum Training des neuronalen Netzes verwendet. Mit den Nahtaufnahmen der Testmenge wird eine Antwort des trainierten Netzes abgerufen und mit der korrekten Antwort verglichen.

Im Anschluß an die Klassifikationen werden die Merkmale und die Gittergeometrien anhand folgender Kriterien beurteilt:

- Während der Nahtstreifen der rosa Serie, der in die Notenklasse 1 fällt („rosa/Note 1“), große Amplituden der Wellen (in Form von Grauwerten) aufweist, sind die Amplituden bei dem Nahtstreifen „schwarz/Note 1“ nicht so ausgeprägt.
- Bei dem Nahtstreifen „rosa/Note 5“ ist trotz seiner als „nicht wellig“ eingestuften Benotung noch eine leichte Wellenbildung zu erkennen, wohingegen der Streifen „schwarz/Note 5“ völlig glatt erscheint.²
- Bei der Welligkeit im Bereich des Nahtverlaufs sind die Frequenzen, wie bereits erwähnt, sehr unterschiedlich. Bei dem Streifen „rosa/Note 1“ ist eine Welligkeit der Wellenzahl ≈ 25 auszumachen, bei dem Streifen „schwarz/Note 1“ die Wellenzahl ≈ 12 .

Das Vorhandensein dieser Uneinheitlichkeiten erschwert die Auswahl guter, gewebetypunabhängiger Merkmale.

6.2.1. Fourier-Transformation

Für eine computerbasierte Klassifikation ist es erforderlich, die Welligkeiten in einer mathematischen Form darzustellen. Ein bewährtes Mittel zur Beschreibung von Wellen, welches auch im vorliegenden Fall Verwendung finden wird, bietet die *Fourier-Transformation* (FT). Literatur zur FT befindet sich in [Press et al., 1992] oder [Schwartz, 1970]. Die Definition und Interpretation der FT wird an dieser Stelle skizziert.

Die FT transformiert die Nahtbilder vom ortsabhängigen Grauertraum G in den Frequenzraum F und ist in der hier verwendeten Form (eindimensionaler, diskreter und endlicher Definitionsbereich) definiert durch die Gleichung

$$X_k = \sum_{m=0}^{N-1} x_m \left(e^{-i2\pi/N} \right)^{km}, \quad k = 0, 1, \dots, N-1 \quad (6.1)$$

In der Definition bezeichnen:

$x_m \in G$:	Datenpunkte des Ortsraumes G (hier die Grauwerte eines eindimensionalen Bildstreifens)
$X_k \in F$:	Datenpunkte des Frequenzraumes F
N :	Dimensionalität der Eingabe
i :	die komplexe Zahl $\sqrt{-1}$

Das Ergebnis der FT, die Werte X_k , sind im allgemeinen komplexe Zahlen³

$$X_k = \|X_k\| e^{i\angle X_k}$$

und lassen sich folgendermaßen interpretieren: Jede periodische (und in diesem Fall diskrete) Funktion bzw. Folge $\{f_m\}_{m=0\dots N-1}$ läßt sich als Summe von Sinuswellen verschiedener Wellenzahlen k approximieren; dies gilt auch für die Funktion $\{x_m\}_{m=0\dots N-1}$, die in (6.1) fouriertransformiert wurde:

$$x_m = \frac{1}{N} \sum_{k=0}^{N-1} z_k \cos(2\pi km/N + \varphi_k) \quad (6.2)$$

Die Fouriertransformierte X_k liefert in diesem Zusammenhang die Information über Amplituden und Phasenverschiebung dieser Sinuswellen.

- $\|X_k\| = z_k$ bestimmt die Amplitude der Schwingung der Wellenzahl k
- $\angle X_k = \varphi_k$ bestimmt die Phase der Schwingung der Wellenzahl k

Die Fourier-Transformation ist somit ein geeigneter Ansatz, um die Dominanz verschiedener Frequenzen in den Nahtbildern wiederzugeben (durch den Wert $\|X_k\|$).

²Eine Begründung dafür könnte sein, daß der rosa Nylonstoff zu den schwierig zu verarbeitenden Geweben gehört und von der Fachkraft eventuell wohlwollender beurteilt wird.

³ $\|X_k\|$ beschreibt die Länge von X_k in der komplexen Ebene und $\angle X_k$ den Winkel zur reellen Achse

6. Merkmalsextraktion

6.2.2. Definition der Merkmalstypen

Unter Verwendung der eindimensionalen Fourier-Transformation werden erste Ansätze für die Merkmalsbildung gewählt. Für alle Ansätze gilt, daß vor der Berechnung der FT die Grauwerte des Bildes linear transformiert werden, so daß anschließend der Mittelwert der Grauwerte η_G im Nullpunkt liegt, $\eta_G = 0$. Dadurch werden eventuelle Helligkeitsverschiebungen unter verschiedenen Geweben eliminiert.

Folgende Merkmalstypen werden gewählt:

1. *Grauwert-Varianz*: Die Varianz der Grauwerte des gesamten Bildes, σ_G^2 wird als eindimensionaler Merkmalsvektor verwendet. Die Wahl dieses Merkmals ist dadurch motiviert, daß in den Abbildungen 3.1-3.3 eine Korrelation zwischen σ_G^2 und den Benotungen zu erkennen ist.
2. *Streifen-Spektrum*: Hierfür wird ein 1-pixel-breiter Längsstreifen des Bildes (in Nahrichtung) an einer Pixel-Position $x \in [0 \dots 79]$ entnommen, von den Grauwerten dieses Streifens das eindimensionale Fourier-Spektrum $\{\|X_k\|\}_{k=0\dots 19}$ berechnet und als Merkmalsvektor verwendet.
3. *Mittelwert-Spektrum*: Es werden die Grauwerte des Bildes in Querrichtung (senkrecht zur Naht) gemittelt, von den gemittelten Grauwerten wird das eindimensionale Fourier-Spektrum $\{\|X_k\|\}_{k=0\dots 19}$ berechnet und als Merkmal verwendet.
4. *Streifen-Spektrum-Intervall*: wie *Streifen-Spektrum*, jedoch werden die Werte des Spektrums $\{\|X_k\|\}_{k=0\dots 19}$ in 5 gleich große, aufeinanderfolgende Intervalle $\{\{\|X_0\|, \dots, \|X_3\|\}, \dots, \{\|X_{16}\|, \dots, \|X_{19}\|\}\}$, jeweils bestehend aus 4 Wellenzahlen, gruppiert und innerhalb derer gemittelt.
5. *Mittelwert-Spektrum-Intervall*: wie *Mittelwert-Spektrum*, jedoch werden die Werte des Spektrums $\{\|X_k\|\}_{k=0\dots 19}$ in 5 gleich große Intervalle $\{\{\|X_0\|, \dots, \|X_3\|\}, \dots, \{\|X_{16}\|, \dots, \|X_{19}\|\}\}$, jeweils bestehend aus 4 Wellenzahlen, gruppiert und innerhalb derer gemittelt.
6. *Hauptfrequenzen*: Es wird für die vier Längsstreifen an den Positionen $x = 10, 30, 50$ und 70 das eindimensionale Fourier-Spektrum $\{\|X_k\|\}_{k=0\dots 256}$ berechnet und von diesem jeweils das Argument-Maximum (= die dominierende Wellenzahl) und das Maximum (= Amplitude dieser Wellenzahl) als Merkmal verwendet. Zusammen ergibt dies also einen 8-dimensionalen Merkmalsvektor.

Die Merkmale 2-6 werden über das Fourier-Spektrum $\|X\|$ definiert, welches von einer Pixel- oder Streifenposition x , an der die eindimensionale FT berechnet wird, und einer Wellenzahl k abhängt. Um eine Vorstellung von der innerhalb dieser Arbeit wichtigen Darstellungsweise der Nähte zu bekommen, ist in Abbildung 6.2 das Spektrum einer bereits bekannten Naht, das der Naht „rosa/Note 1“ aus Abbildung 6.1, abgebildet. Zu sehen ist dort, daß sich lokale Maxima des Spektrums am Rand des Nahtstreifens für die Wellenzahl $k \approx 6$ und direkt neben dem Nahtverlauf für die Wellenzahl $k \approx 22$ befinden.

6.2.3. Definition der Klassifikatoren

Die Klassifikatoren, die in den Probeklassifikationen eingesetzt werden, sind definiert durch die 12 Merkmalsvektoren

- $1 \times$ *Grauwert-Varianz* (1-dimensional)
- $4 \times$ *Streifen-Spektrum* (an den Pixel-Positionen 10, 30, 50 und 70, jeweils 20-dimensional)
- $1 \times$ *Mittelwert-Spektrum* (20-dimensional)
- $4 \times$ *Streifen-Spektrum-Intervall* (an den Pixel-Positionen 10, 30, 50 und 70, jeweils 5-dimensional)

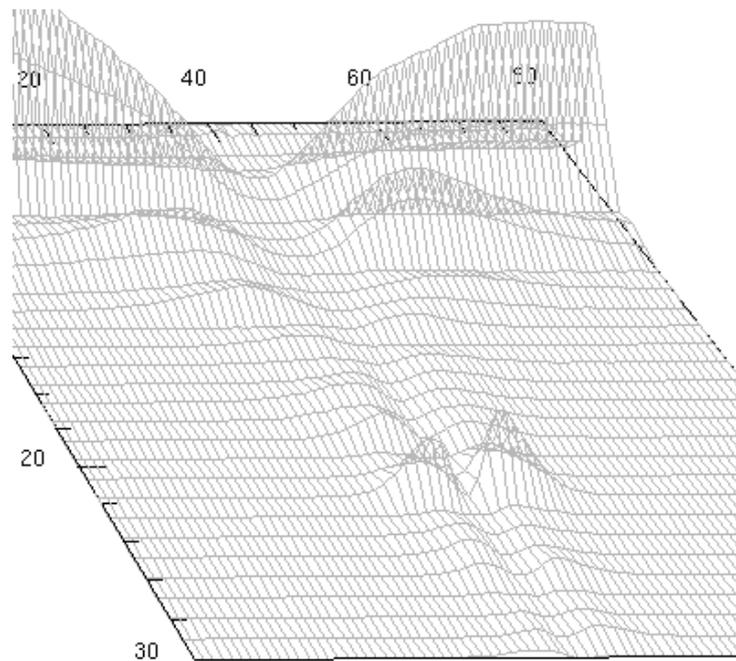


Abbildung 6.2.: Fourier-Spektrum $\|X\|$ der Naht „rosa/Note 1“ aus Abbildung 6.1: Auf der aus der Bildebene herauskommenden Achse sind die Wellenzahlen $k = [0 \dots 30]$ aufgetragen, auf der im hinteren Teil verlaufenden Achse die Pixel-Positionen $p = [0 \dots 79]$ und nach oben das Fourier-Spektrum $\|X(k, x)\|$. Gut zu erkennen sind lokale Maxima des Spektrums für die Wellenzahl $k \approx 6$ am Rand des Nahtstreifens und direkt neben dem Nahtverlauf für die Wellenzahl $k \approx 22$. Es ist noch zu erwähnen, daß das Fourier-Spektrum nicht nur 31, sondern 257 Komponenten besitzt. Jedoch sind die Werte für die hohen Wellenzahlen annähernd null, so daß sie hier nicht aufgetragen werden.

6. Merkmalsextraktion

- $1 \times$ *Mittelwert-Spektrum-Intervall* (5-dimensional)
- $1 \times$ *Hauptfrequenzen* (8-dimensional)

und die 8 verschieden gewählten Geometrien des Kohonennetzes, die bereits in Kapitel 5.3.3 festgelegt wurden

- $5 \times 1, 10 \times 1, 25 \times 1, 100 \times 1, 3 \times 3, 5 \times 2, 5 \times 5, 10 \times 10$.

Insgesamt ergibt dies $12 \cdot 8 = 96$ verschiedene Klassifikatoren.

6.2.4. Resultate der Probeklassifikationen

In den folgenden Abschnitten soll die Leistungsfähigkeit der Klassifikatoren anhand der in Kapitel 6.1 bereits angekündigten Beurteilungskriterien *NMSE*, *Verwechslungsmatrix*, *MSE* und einer *Untersuchung der Kohonenkarte* interpretiert werden.

6.2.4.1. Der NMSE der Probeklassifikationen

Der NMSE (normalized mean square error) gibt den mittleren quadratischen Fehler der Klassifikation, normiert durch die Varianz der Klassen, an:

$$\text{NMSE} = \frac{1}{\sigma_k^2 N} \sum_{\alpha=1}^N (k_S^\alpha - k_N^\alpha)^2 \quad (6.3)$$

Dabei bezeichnen k_S^α und k_N^α die (hier rationalwertige) Sollklasse bzw. die Netzantwort, der Index α indiziert die einzelnen Testnähte, N bezeichnet die Anzahl der Testnähte und σ_k^2 die Varianz der Notenklassen.

Um statistisch zuverlässige Ergebnisse zu erhalten, wird der NMSE aus 20 unabhängigen Klassifikationsläufen gemittelt.

Die NMSE's der Probeklassifikationen sind in einem Schaubild in Abbildung 6.3 dargestellt. Dort sind die Funktionsgraphen des NMSE in Abhängigkeit der Klassifikationsmerkmale für die verschiedenen Gittergeometrien aufgetragen.

Einige Aussagen, die aus dem Schaubild zu ersehen sind, werden im folgenden zusammengefaßt:

- Die verschiedenen Graphen (jeder Graph repräsentiert eine Gittergeometrie) weisen einen qualitativ ähnlichen Verlauf auf. Besonders ausgeprägt ist die Ähnlichkeit unter Geometrien der gleichen Dimension (zum Beispiel beim Vergleich vom 5×5 (rot) und 10×10 -Gitter (gelb)).
- Der kleinste NMSE wird für fast alle Gittergeometrien mit dem *Streifen-Spektrum-Intervall* an der Pixel-Position $x = 10$ erzielt (NMSE = 0.14 für das 100×1 -Gitter).
- Bemerkenswerterweise klassifiziert das *Streifen-Spektrum-Intervall* an der Pixel-Position $x = 70$, d.h. an der zur Stelle $x = 10$ symmetrischen Position, wesentlich schlechter (NMSE = 0.29 für das 100×1 -Gitter). Dies läßt darauf schließen, daß eine gute Auswahl der Streifenposition x nicht sicher zu treffen ist.
- Sowohl eine Berücksichtigung der inneren Welligkeit (Pixel-Position 50) als auch der äußeren (Pixel-Position 10) erweisen sich als erfolgreiches Klassifikationskriterium.
- Das Zusammenfassen von Wellenzahlen zu einem Intervall (wie beim *Streifen-Spektrum-Intervall*) führt in den meisten Fällen zu einer Verkleinerung des NMSE.
- Die Grauwert-Varianz ist als Merkmal ungeeignet. Die Tatsache kann dadurch begründet werden, daß dieses Merkmal stark von der Nahtserie abhängt.

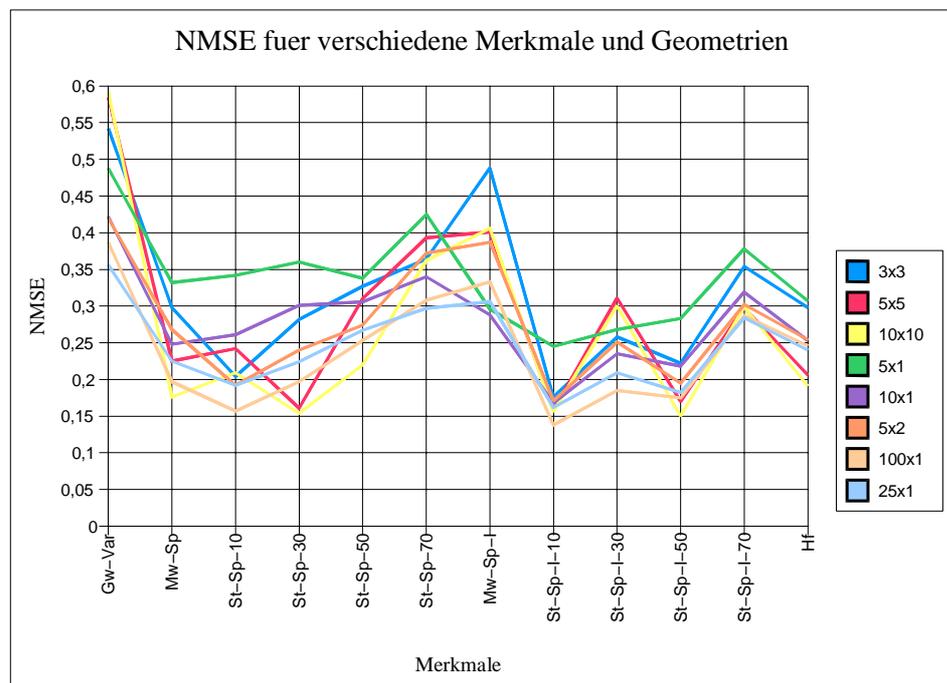


Abbildung 6.3.: Klassifikationsergebnisse für die verschiedenen Merkmale und Gittergeometrien. Auf der Abszisse sind die verwendeten Klassifikationsmerkmale (abgekürzt durch die Anfangsbuchstaben ihres vollständigen Namens: Gw = Grauwert, Var = Varianz, Mw = Mittelwert, St = Streifen, Sp = Spektrum, I = Intervall, Hf = Hauptfrequenzen, *Zahlenwerte* = *x*-Pixel-Position) und auf der Ordinate ist der Klassifikationsfehler NMSE aufgetragen. Jeder Funktionsgraph entspricht einer Gittergeometrie des Kohonennetzes, mit dem die Klassifikation durchgeführt wurde.

6. Merkmalsextraktion

An dieser Stelle kann ein Vergleich des erzielten NMSE mit den von Fachkräften durchgeführten Begutachtungen angestellt werden. Dies geschieht auf folgende Weise: Für die Nahtbeispiele der rosa Nähte liegen die jeweils rationalwertigen Expertenbenotungen von drei Fachkräften vor. Damit kann die normierte mittlere Varianz der Expertenbenotung

$$\sigma_{EB}^2 = \frac{1}{\sigma_k^2 N} \sum_{\alpha=1}^N \frac{1}{3} \sum_{i=1}^3 (k_i^\alpha - \eta_k^\alpha)^2$$
$$\eta_k^\alpha = \frac{1}{3} \sum_{i=1}^3 k_i^\alpha$$

(i mittelt über alle drei Experten und α über die N Beispiele) berechnet werden. Dieses Maß der Uneinigkeit unter den Experten ist ein geeigneter Vergleichswert mit dem oben berechneten NMSE unter der Voraussetzung, daß der Mittelwert η_k^α der Expertenbenotungen als Sollklasse k_S^α angenommen wird.

Der Wert für σ_{EB}^2 berechnet sich im vorliegenden Fall zu $\sigma_{EB}^2 = 0.05$. Dies ist ein besserer Wert als der bisher erzielte kleinste NMSE, 0.14, jedoch besteht zwischen den beiden Fehlermaßen nur ein Unterschied von einem Faktor 3.

6.2.4.2. Die Verwechslungsmatrix der Probeklassifikationen

Zu einer weiteren Interpretation der Klassifikationsgüte soll untersucht werden, ob es ausgezeichnete Notenklassen gibt, in denen besonders schlecht bzw. gut klassifiziert wird. Weiterhin ist es interessant, zu erfahren, wie groß die Fehlklassifikationen im einzelnen ausfallen.

Diese Fragestellungen können mit Hilfe einer *Verwechslungsmatrix* beantwortet werden. Zur Berechnung der Verwechslungsmatrix werden die einzelnen Klassifikationen des Testvorganges protokolliert. Ergebnis des Protokollierens ist eine Matrix, die für jede Klasse je eine Spalte und eine Zeile besitzt. Ein Matrixelement (i, j) gibt die Anzahl der Klassifikationen eines Testbeispiels der Klasse j in die Klasse i an. Das bedeutet, daß das System die Testbeispiele umso korrekter klassifiziert, je mehr Einträge im Bereich der Hauptdiagonalen vorgenommen wurden.

Im vorliegenden Fall ist zu beachten, daß sowohl die Expertenbenotung k_S als auch die Netzantwort k_N aus rationalen Werten bestehen. Das bedeutet, daß k_S und k_N zur Bestimmung ihres entsprechenden Matrixelementes gerundet werden müssen. Die Rundung wird sinnigerweise auf ganze Zahlen vorgenommen, weil dies schließlich wieder den in der Textilindustrie üblichen Notenklassen entspricht. Die Rundung führt demnach zu einer Zeilen- und Spaltenanzahl der Verwechslungsmatrix von jeweils fünf.

In Abbildung 6.4 wird die Verwechslungsmatrix als Zahlenmatrix und Balkendiagramm für unterschiedliche Klassifikatoren gezeigt. Grundlage der Berechnung waren 20 unabhängige Probeklassifikationen.

Aus Abbildung 6.4 lassen sich folgenden Aussagen über das Klassifikationsverhalten ableiten:

- Fast jede Fehlklassifikation liegt nur um eine Note von der Sollklasse entfernt.
- Besonders gut werden Probenähte der Sollklassen 2 und 4 klassifiziert.
- Sämtliche Probenähte der Benotung 5 (glatte Nähte) werden in die Klasse 4, also eine Klasse schlechter, eingeordnet. Eine Begründung für diesen Tatbestand ist, daß nur sehr wenige Probenähte in diese Klasse fallen. In der Trainingsmenge sind dies zwei, in der Testmenge drei. Das relativ schlechte Klassifikationsergebnis für die Testnähte der Klasse 3 kann ebenfalls mit der kleinen Anzahl von Probenähten innerhalb dieser Klasse begründet werden.

Die Aussage von Punkt 1, d.h. die Feststellung eines Klassifikationsfehlers e von $e \leq 1$, läßt eine neue Interpretationsmöglichkeit der Klassifikationsergebnisse entstehen: der MSE (mean square error) ist mit dieser Eigenschaft identisch mit Wahrscheinlichkeit einer Fehlklassifikation.

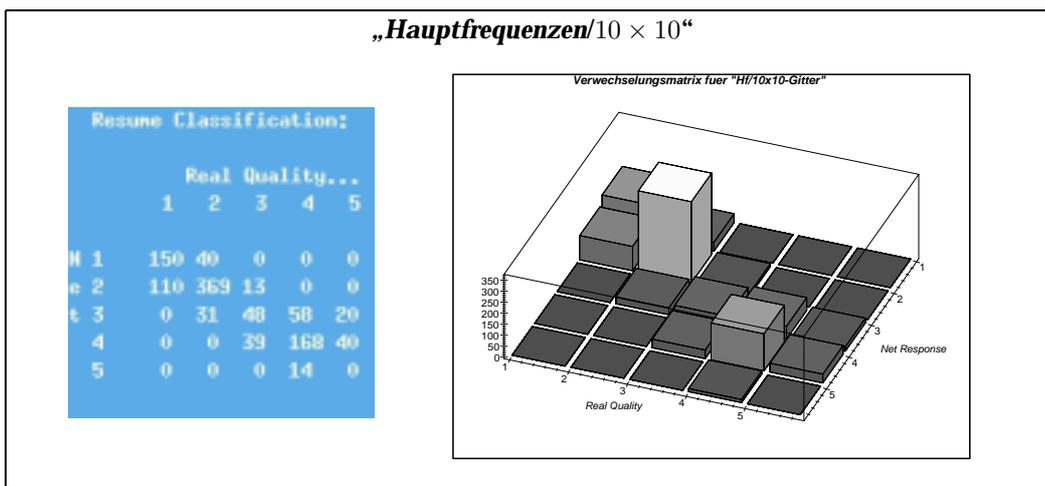
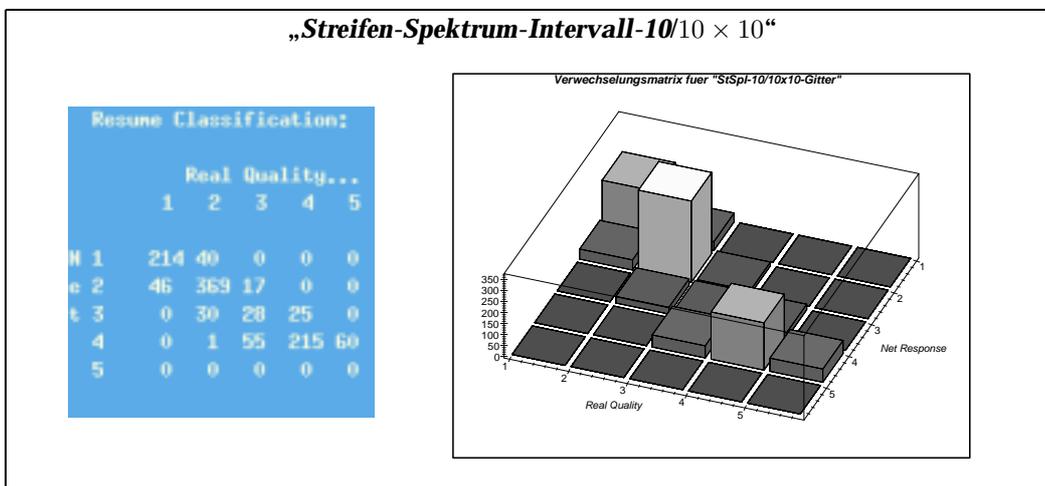
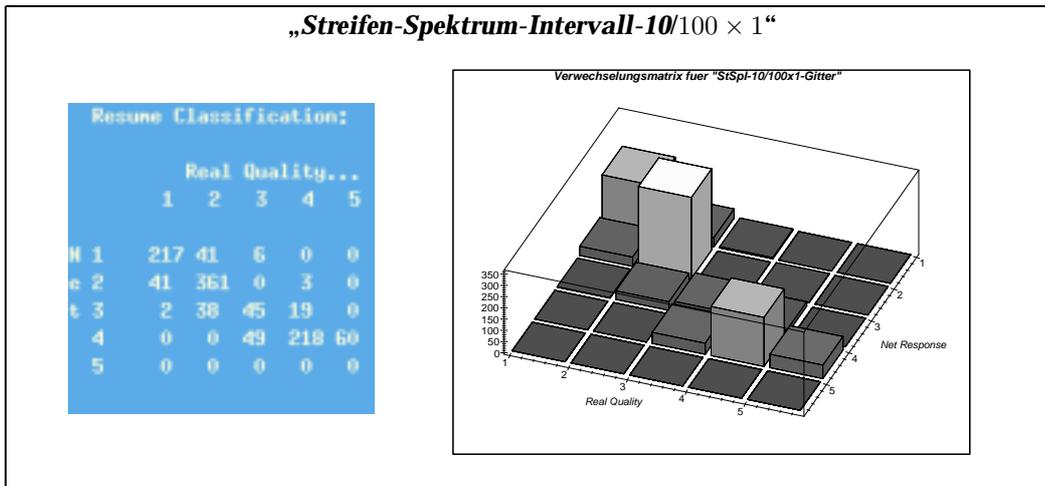


Abbildung 6.4: Verwechslungsmatrizen für verschiedene Klassifikatoren, links als Zahlenmatrix, rechts als Balkendiagramm. Die Matrizen zeigen, daß die meisten Fehlklassifikationen nur eine Notenklasse betragen. Die Matrix berechnet sich aus 20 voneinander unabhängigen Klassifikationsläufen.

6. Merkmalsextraktion

6.2.4.3. Der MSE als Maß der Wahrscheinlichkeit einer Fehlklassifikation

Der MSE (mean square error) bezeichnet den mittleren quadratischen Fehler einer Klassifikation und ist ähnlich wie der NMSE (6.3) definiert als

$$\text{MSE} = \frac{1}{N} \sum_{\alpha=1}^N (k_S^\alpha - k_N^\alpha)^2 = \sigma_k^2 \cdot \text{NMSE}$$

In dem hier vorliegenden Fall, daß ein Klassifikationsfehler $e^\alpha = k_S^\alpha - k_N^\alpha$ eines Beispiels α , entweder null oder eins beträgt, $e^\alpha \in \{0, 1\}$, läßt sich zeigen, daß der MSE der Wahrscheinlichkeit einer Fehlklassifikation $p_e = \frac{1}{N} \sum_{\alpha=1}^N e^\alpha$ entspricht:

$$\text{MSE} = \frac{1}{N} \sum_{\alpha=1}^N (e^\alpha)^2 = \frac{1}{N} \sum_{\alpha=1}^N e^\alpha = p_e$$

Die Varianz der Klassen liegt bei den benutzten Trainings- und Testbeispielen bei $\sigma_k^2 \approx 1.5$. Damit kann die Wahrscheinlichkeit einer Fehlklassifikation p_e ebenfalls in Abbildung 6.3 abgelesen werden. Für diesen Zweck ist es erforderlich, die Ordinatenachse mit einem Faktor $s = 1.5$ zu skalieren. Für das *Streifen-Spektrum-Intervall-10* ergibt sich somit $p_e = 0.14 \cdot 1.5 = 0.21$. Das bedeutet, daß das System in diesem Fall vier von fünf Probestreifen korrekt in die ganzzahligen Notenklassen einordnet.

6.2.4.4. Untersuchung der im Trainingsprozeß entstandenen Kohonenkarte

In diesem Abschnitt wird von der Möglichkeit Gebrauch gemacht, die bei der Klassifikation verwendeten ein- bzw. zweidimensionalen Kohonenkarten zu visualisieren und deren Struktur zu untersuchen. Die Fragestellungen, die auf diese Weise beantwortet werden können, sind z.B.:

- Welche Regionen repräsentieren in der Kartenstruktur welche Notenklassen? Ist diese Struktur geordnet?
- Wie gut werden die Testbeispiele in die ihnen entsprechenden Regionen abgebildet?
- Werden ähnlich benotete Nähte aus unterschiedlichen Nahtserien in benachbarte Regionen der Karte abgebildet?

Die Vorgehensweise zur Beantwortung obiger Fragestellungen besteht darin, das Neuronengitter als zweidimensionale Matrix abzubilden und an den Positionen der Neuronen bestimmte Informationen einzutragen. Das kann z.B. sein:

- die Antwort (Klasse), die ein Neuron als Ausgabe erzeugt oder
- die Sollklasse des Testbeispiels, welches das Neuron erregt hat

Diese beiden Vorgehensweisen sind verfolgt worden und die Ergebnisse werden in den Abbildungen 6.5–6.7 gezeigt.

In den jeweils linken oberen Schaubildern ist der Ausgabewert jedes Neurons an seiner Position im Gitter eingetragen. Dabei sind die Notenklassen zusätzlich farblich voneinander getrennt. In diesen Schaubildern kann untersucht werden, ob benachbarte Neuronen des Netzes ähnliche Ausgaben erzeugen, so wie es bei topologieerhaltenden Abbildungen, zu denen die Kohonenkarte gehört, idealerweise der Fall ist (nähere Erläuterungen dazu in Kapitel 5).

In den rechten oberen Schaubildern ist eingetragen, welche Notenklassen bei dem Testdurchgang die jeweiligen Neuronen zur Erregung gebracht haben. Durch einen Vergleich mit dem linken Bild kann überprüft werden, ob die Testbeispiele ein Neuron der korrekten Klasse erregen. Die eingetragenen Sollklassen sind farblich durch ihre Klassenzugehörigkeit gekennzeichnet.

Die Sollantwort der Testbeispiele ist ein weiteres Mal im unteren Bild zu sehen. Hier ist jedoch die Farbsemantik eine andere als bei den oberen Bildern. Durch die Farben

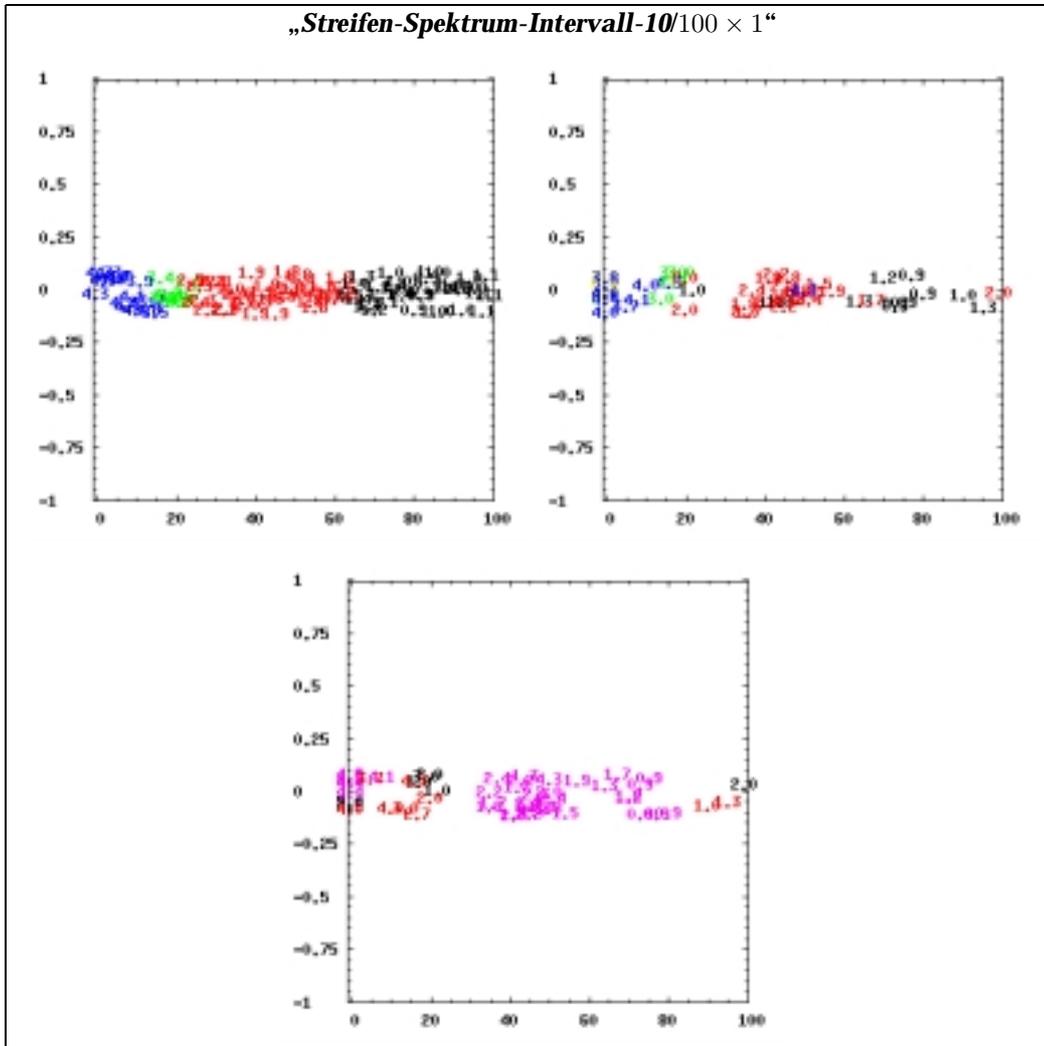


Abbildung 6.5.: Das Kohonen-Netz, wie es sich im Lernalgorithmus gebildet hat, für den Klassifikator „*Streifen-Spektrum-Intervall-10/100 × 1*“: In dem linken oberen Bild sind die Ausgabewerte aller Neuronen an deren Position eingetragen. Die verschiedenen Farben symbolisieren die Zugehörigkeit der Neuronen zu den ganzzahligen Notenklassen 1, 2, 3, 4 und 5. In allen drei Schaubildern ist zu beachten, daß in den Karten zum Zweck einer besseren Lesbarkeit der Zahlenwerte ihre Positionen mit einer gaußschen Zufallszahl verschoben wurden und sie somit nicht exakt auf ihren Gitterpositionen eingetragen sind. Aus diesem Grund dehnt sich die eindimensionale Kette in diesen Schaubildern in einer zusätzlichen, zweiten Dimension aus. Im rechten oberen Schaubild sind die Sollklassen der Testnähte an der Position eingetragen, die dem Siegerneuron des jeweiligen Klassifikationsschrittes entspricht. Idealerweise müßten sie Regionen der Karte zugeordnet werden, die ihrer Sollklasse entsprechen. Die Farben kennzeichnen wieder die Zugehörigkeit der rationalwertigen Klassifikationsausgabe zu den diskreten Notenklassen. Im unteren Bild sind die Sollklassen der Testbeispiele ein weiteres Mal an den entsprechenden Positionen eingetragen. Hier haben die Farben jedoch eine andere Semantik: Rosa, rote und schwarze Werte geben die Zugehörigkeit der Testbeispiele zu den rosa, roten bzw. schwarzen Nahtserien an.

6. Merkmalsextraktion

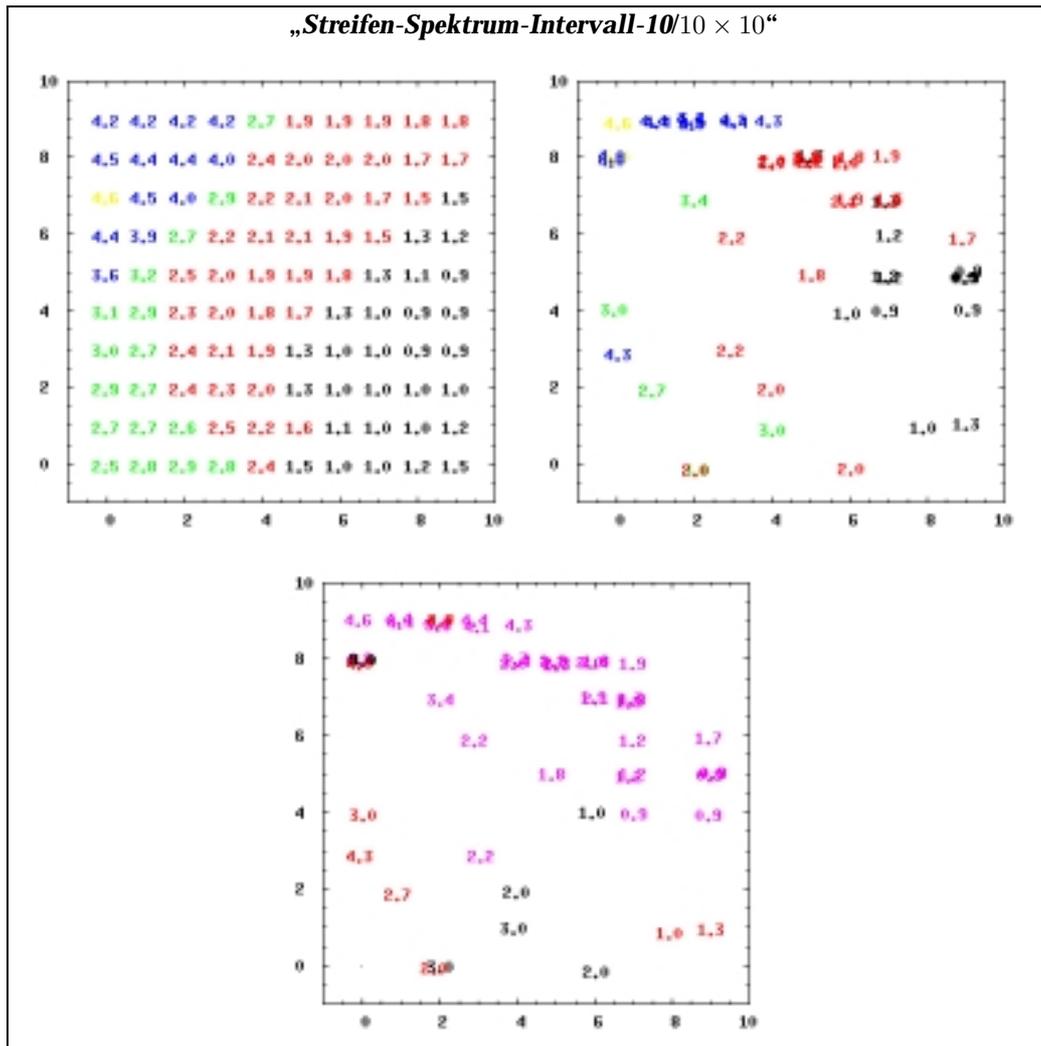


Abbildung 6.6.: Das Kohonen-Netz, wie es sich im Lernalgorithmus gebildet hat, für den Klassifikator „Streifen-Spektrum-Intervall- $10/10 \times 10$ “ (weitere Erläuterungen siehe Abbildung 6.5).

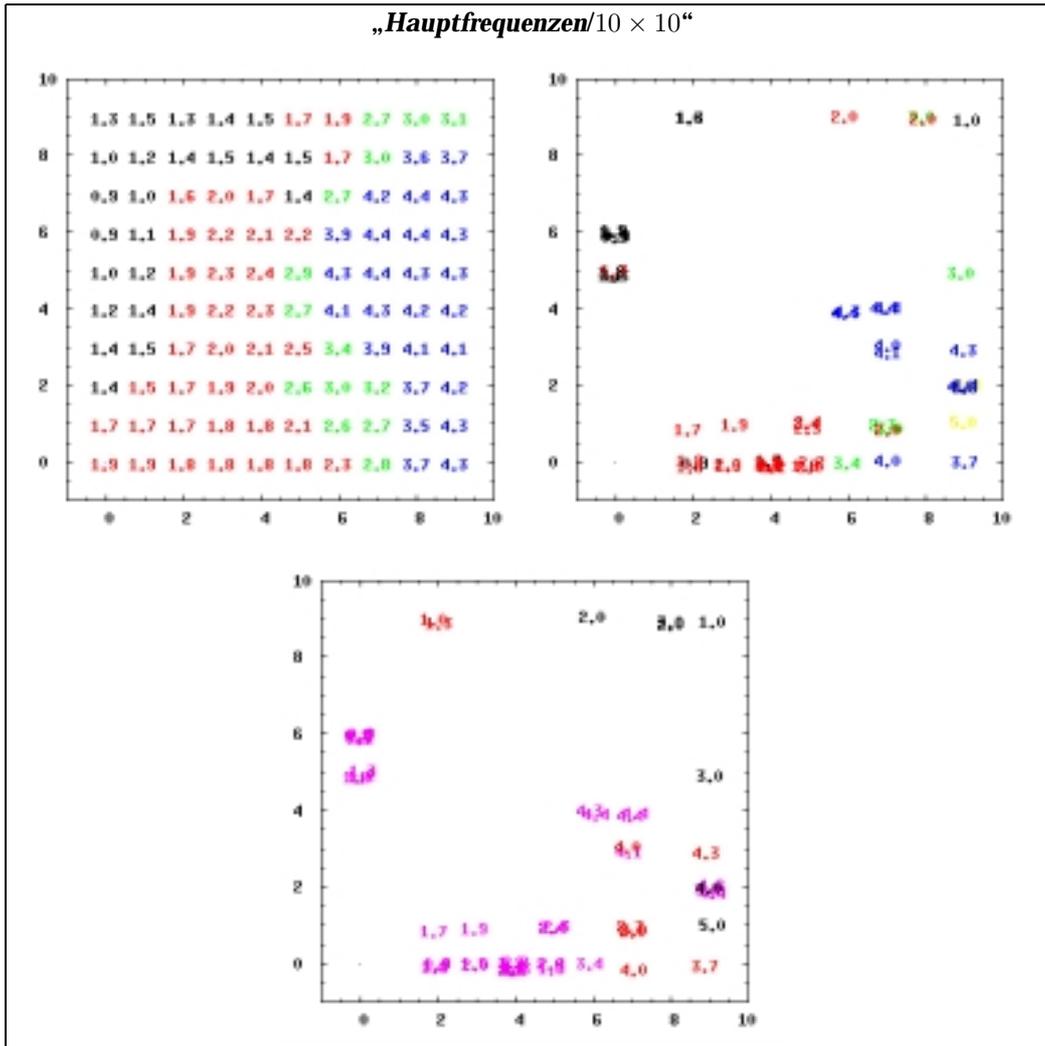


Abbildung 6.7.: Das Kohonen-Netz, wie es sich im Lernalgorithmus gebildet hat, für den Klassifikator „Hauptfrequenzen/ 10×10^4 “ (weitere Erläuterungen siehe Abbildung 6.5).

6. Merkmalsextraktion

rosa, schwarz und rot wird die Zugehörigkeit der Testbeispiele zu der rosa, schwarzen bzw. roten Nahtstreifenserie gekennzeichnet.

Aus den Abbildungen 6.5–6.7 können folgende Schlußfolgerungen gezogen werden:

- Bei allen Klassifikatoren liegt eine gute Monotonie in der Neuronenordnung vor (siehe jeweils linkes oberes Schaubild). Auffallend ist jedoch, daß der Klasse 3 und besonders der Klasse 5 wenig Neuronen zugeschrieben werden. Bei der eindimensionalen Neuronenkette und beim *Hauptfrequenzen*-Gitter hat sich sogar nicht ein Neuron für die Klasse 5 herausgebildet. Eine Begründung hierfür ist, daß Testbeispiele dieser Klasse nur in einer geringen Anzahl vorhanden sind (vergleiche dazu die Balkendiagramme in Abbildung 6.4).
- Die Einteilung der Testbeispiele auf die Neuronen erfolgt in den meisten Fällen korrekt (siehe rechtes oberes Schaubild). Es ist zudem zu erkennen, daß das Beispiel der Klasse 5 auf 4er-Neuronen abgebildet wird, deren Ausgabe nahe an der Klasse 5 liegt.
- Die Testbeispiele der rosa Serie werden, insbesondere beim *Streifen-Spektrum-Intervall-10*, überwiegend in die korrekten Regionen eingeordnet (siehe unteres Schaubild). Größere Fehlklassifikationen entstehen nur bei Beispielen der roten und schwarzen Serie. Eine Begründung für diesen Sachverhalt kann sein, daß diese Serien in der Anzahl unterrepräsentiert sind.
- Nahtbilder der roten oder schwarzen Serie ordnen sich meistens in andere Kartenregionen ein als Bilder der rosa Serie. Daraus kann geschlossen werden, daß sie auch im Merkmalsraum anderen Regionen entsprechen. Am ausgeprägtesten ist dies beim Klassifikator „*Streifen-Spektrum-Intervall-10/10 × 10*“ zu erkennen. Hier erregen rosa Probenächte Neuronen in der rechten oberen Kartenhälfte und Beispiele der roten und schwarzen Serie Neuronen in der linken unteren Hälfte.

6.3. Weiterentwicklung der Merkmale

Im bisherigen Verlauf der Merkmalsauswahl wurden die meisten Merkmale mit Hilfe des Fourier-Spektrums $\|X\|$ definiert. Diese Größe hängt von der Pixel-Position x , an der die eindimensionale Fourier-Transformation X berechnet wird, und der Wellenzahl k ab (vergleiche dazu auch Abbildung 6.2). Zur Berechnung der Merkmalselemente wurden sowohl das Spektrum einer einzelnen Wellenzahl k als auch ein gemittelter Wert für mehrere Wellenzahlen $\{k_m \dots k_n\}$ (bei den *Intervall*-Merkmalen) herangezogen.

Die Auswahl von x und k bzw. $\{k_m \dots k_n\}$ wurde dabei jedoch mehr oder weniger willkürlich getroffen. Dies kann dazu führen, daß Spektren berücksichtigt werden, die nur wenig oder gar nicht mit den Notenklassen korreliert sind. Es ist ebenfalls denkbar, daß die Spektren des zu mittelnden Intervalls $\{k_m \dots k_n\}$ untereinander unkorreliert sind und damit interferieren. Beides würde störenden Einfluß auf eine erfolgreiche Klassifikation haben.

Ansätze zu einer Verbesserung der bisher vorgenommenen Merkmalsdefinitionen bestehen deshalb darin,

- nicht relevante Wellenzahlen oder auch Streifenpositionen auszusortieren und
- bei der Zusammenfassung mehrerer Spektren die Korrelation untereinander zu berücksichtigen.

Diese Ansätze sollen im Verlauf dieses Kapitels verfolgt und auf ihren praktischen Erfolg überprüft werden.

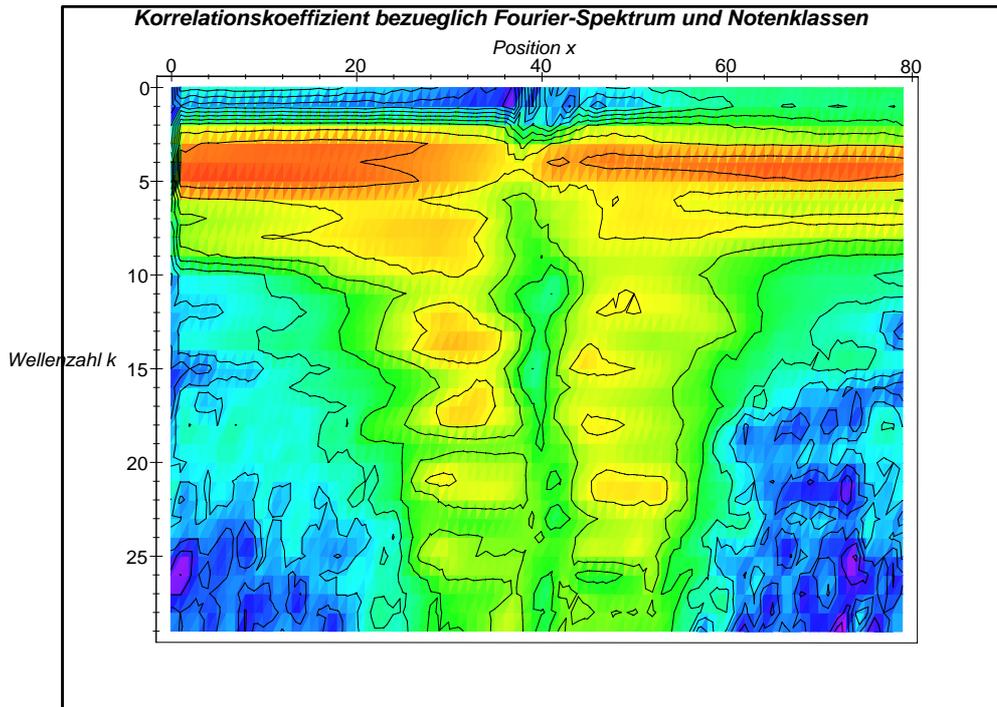


Abbildung 6.8.: Der Korrelationskoeffizient $\rho_{\|X\|N}(k, x)$ des Fourier-Spektrums $\|X(k, x)\|$ und der Notenklassen N in Abhängigkeit von der Position x und der Wellenzahl k des Spektrums. Blaue Regionen geben unkorrelierte Gebiete an, grüne eine leichte negative Korrelation ($\rho_{\|X\|N} = -0.2 \dots -0.4$) und rote eine stärkere negative Korrelation ($\rho_{\|X\|N} = -0.4 \dots -0.7$).

6.3.1. Die Korrelation von Fourier-Spektrum und Notenklassen

Wie bereits erläutert, ist es von großem Interesse, Positionen des zweidimensionalen Raumes $P \times K$ der Pixel-Positionen $x \in P$ und der Wellenzahlen $k \in K$ herauszufinden, an denen eine hohe Korrelation von Fourier-Spektrum $\|X(k, x)\|$ und Notenklassen N besteht. Das Fourier-Spektrum $\|X(k_0, x_0)\|$ einer solchen Position (k_0, x_0) enthält hilfreiche Information über die Notenklasse und es ist lohnenswert, seinen Wert bei der Definition eines Merkmals zu berücksichtigen.

Ein mathematisches Maß für die Korrelation zwischen zwei Größen A und B ist der *Korrelationskoeffizient* ρ_{AB} . In Kapitel A.2 werden dessen Definition und Eigenschaften beschrieben.

In dem hier behandelten Fall der Korrelation zwischen Fourier-Spektrum $\|X(k, x)\|$ und Notenklasse N ist der Korrelationskoeffizient $\rho_{\|X\|N}$ wegen der (k, x) -Abhängigkeit von $\|X\|$ ebenfalls eine von k und x abhängige Größe, d.h. $\rho_{\|X\|N} = \rho_{\|X\|N}(k, x)$.

Er ist auf der Basis der vorhandenen Probennähte berechnet worden und wird in Abbildung 6.8 gezeigt. Auf der horizontalen Achse ist die Position x und auf der vertikalen Achse die Wellenzahl k des Spektrums $\|X(k, x)\|$ angegeben. Der Wert von $\rho_{\|X\|N}$ wird durch die Farbe dargestellt: blaue Regionen geben unkorrelierte Gebiete an, grüne eine leichte negative Korrelation ($\rho_{\|X\|N} = -0.2 \dots -0.4$) und rote eine stärkere negative Korrelation ($\rho_{\|X\|N} = -0.4 \dots -0.7$).

In dem Schaubild ist zu erkennen, daß das Fourier-Spektrum und die Notenklassen an vielen Positionen antikorreliert sind. Die Antikorrelation wird durch den Tatbestand erklärbar, daß eine hohe Welligkeit von den Nähfachkräften mit einer niedrigen Benotung (Note 1) beurteilt wird. Starke Antikorrelationen liegen in nahtäußeren Regionen bei den Wellenzahlen $k \approx 3 - 5$ und in nahtinneren Regionen unter anderen bei den Wellenzahlen $k \approx 4$, $k \approx 12 - 14$, $k \approx 16 - 18$ und $k \approx 21$. Die größte Korrelation tritt für $(k, x) = (5, 6)$

6. Merkmalsextraktion

auf. Die Berechnung ergab für diesen Wert $\rho_{\|X\|N}(k, x) \approx -0.67$.

In Abbildung 6.8 wird außerdem ersichtlich, warum in Kapitel 6.2.4 ein unterschiedlich gutes Klassifikationsverhalten bezüglich der *Streifen-Spektrum-10-(Intervall)*- und *Streifen-Spektrum-70-(Intervall)*-Merkmale festgestellt wurde: die stark korrelierte Region bei der Wellenzahl $k \approx 4$ erstreckt sich in der linken Hälfte der Naht (Positionen $x = [0 \dots 39]$) über eine größere Anzahl von Wellenzahlen als in der rechten (Positionen $x = [40 \dots 79]$). Damit konnten die *Streifen-Spektrum-10-(Intervall)*-Klassifikatoren auf eine größere Anzahl von korrelierten Wellenzahlen zurückgreifen als die *Streifen-Spektrum-70-(Intervall)*-Klassifikatoren.

An dieser Stelle ist es lohnenswert, noch einmal auf das Aufstellen der Beleuchtungseinrichtung (Kapitel 3.1.3) Bezug zu nehmen und die Korrelationskoeffizienten für die dort zur Auswahl gestellten Winkel zu berechnen. Abbildung 6.9 zeigt Graphen für die vier verschiedenen Beleuchtungswinkel $\alpha = 8^\circ, 13^\circ, 30^\circ, 90^\circ$ und zum Vergleich den bereits bekannten Korrelationskoeffizienten für $\alpha = 20^\circ$.

Dort ist zu erkennen, daß die Korrelation bei dem Beleuchtungswinkel $\alpha = 90^\circ$ von allen Winkeln insgesamt am kleinsten ist. Dieser Tatbestand war auch durch eine Betrachtung der Nahtbilder in Abbildung 3.1 bis 3.3 optisch zu erkennen und führte schließlich zu einem schlechten Klassifikationsresultat.

Abbildung 6.9 zeigt weiterhin, daß sich für $\alpha = 8^\circ$ hohe Korrelationen über einen großen Bereich erstrecken, eingeschlossen hohe Wellenzahlen. Als Begründung dafür kann angeführt werden, daß die extremen Grauwertsprünge des Ortsraumbildes bei welligen Nähten (siehe Abbildung 3.1) in höhere Wellenzahlen fouriertransformiert werden. Die Werte für die Korrelationen sind jedoch bei diesem Winkel vom Betrag um etwa 0.1 kleiner als für $\alpha = 20^\circ$. Die Berechnung ergab einen maximalen Wert von $\rho_{\|X\|N} = -0.58$. Daher fielen die Klassifikationsresultate dort insgesamt schlechter aus.

Die bezüglich der Leistungsfähigkeit der Klassifikation vergleichbaren Winkeleinstellungen, also $\alpha = 13^\circ$ und 30° sind auch bezüglich der Korrelation dem verwendeten Winkel am ähnlichsten. Regionen ausgeprägter Korrelation befinden sich dort auch am Streifenrand bei $k \approx 4$ und in der Nahtmitte für höhere Wellenzahlen.

6.3.2. Definition der erweiterten Klassifikatoren

Unter Berücksichtigung der Ergebnisse aus Kapitel 6.3.1 können neue Merkmale definiert werden, die gezielter auf die mit der Benotung korrelierten Regionen des Fourier-Spektrums $\|X(k, x)\|$ zugreifen. Eine geeignete Auswahl von Wellenzahlen bzw. Wellenzahlenregionen erfolgt mit Hilfe der in Abbildung 6.8 gezeigten Korrelationsinformation. Bei der Bestimmung der zu mittelnden Intervalle wurde angenommen, daß die Spektren benachbarter Wellenzahlen, die zusammen im x - k -Raum ein Maximum bilden, untereinander korreliert sind und so in ein gemeinsames Intervall zusammengefaßt werden können.⁴ Die Wahl der Pixel-Positionen x und der zu mittelnden Wellenzahlen $\{k_m \dots k_n\}$ sind in Tabelle 6.1 zusammengefaßt. In der Tabelle gibt jede der fünf rechten Spalten ein Intervall und somit ein Element des Merkmalsvektors an. Die vier Zeilen bei der Definition der Merkmalsvektoren repräsentieren die vier Positionen $x = 6, 32, 47, 74$ der eindimensionalen FT.

6.3.3. Resultate der Probeklassifikationen mit den erweiterten Merkmalen

Für die in Kapitel 6.3.2 definierten, erweiterten Merkmale E_1, E_2, E_3 und E_4 sind wie in Kapitel 6.2.4 Probeklassifikationen mit den verschiedenen Kohonengitter-Geometrien durchgeführt worden. In diesem Abschnitt werden die Ergebnisse dokumentiert. Dies wird wieder anhand der bereits bekannten Größen und Methoden *NMSE*, *MSE*, *Verwechslungsmatrix* und der *Gestalt der Kohonenkarten* erfolgen.

⁴Diese Annahme ist nicht als selbstverständlich zu betrachten und verdient in Zukunft weitere Untersuchungen.

6.3. Weiterentwicklung der Merkmale

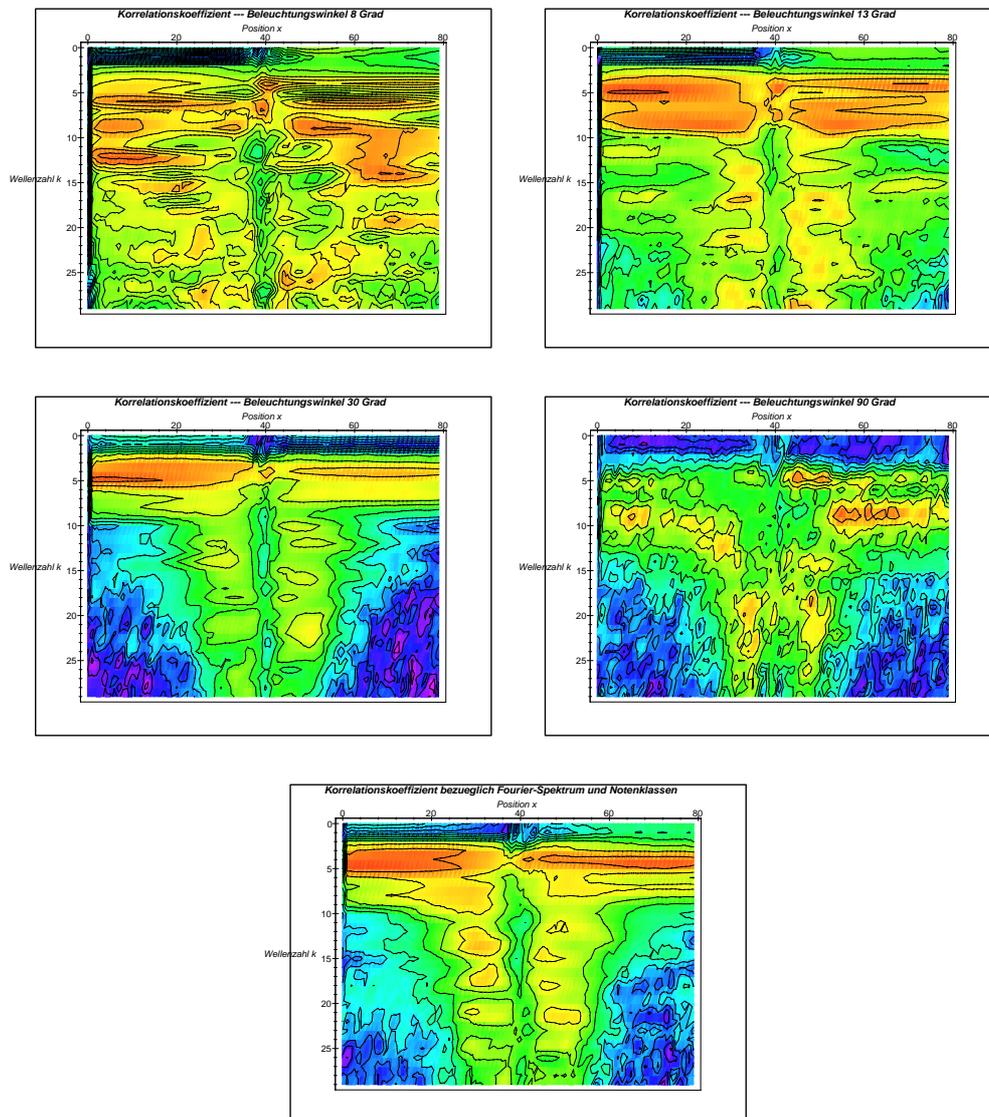


Abbildung 6.9.: Korrelationskoeffizient $\rho_{\|X\|N}(k, x)$ für die in Kapitel 3.1.3 untersuchten Winkel der Beleuchtungsrichtung $\alpha = 8^\circ, 13^\circ, 30^\circ, 90^\circ$. Zum Vergleich ist der bereits bekannte Korrelationskoeffizient für $\alpha = 20^\circ$ mit abgebildet.

6. Merkmalsextraktion

Name des Merkmalsvektors	Position x	Wellenzahlenintervalle $\{k_m \dots k_n\}$				
E_1 (10-dimensional)	74	0-9	—	—	—	—
	47	0-9	10-15	16-19	20-23	—
	32	0-9	10-15	16-19	20-23	—
	6	0-9	—	—	—	—
E_2 (12-dimensional)	74	3-5	—	—	—	—
	47	3-5	7-9	12	15	22
	32	3-5	7-9	13-14	17	21
	6	3-5	—	—	—	—
E_3 (4-dimensional)	74	3-5	—	—	—	—
	47	3-5	—	—	—	—
	32	3-5	—	—	—	—
	6	3-5	—	—	—	—
E_4 (4-dimensional)	74	4	—	—	—	—
	47	4	—	—	—	—
	32	4	—	—	—	—
	6	4	—	—	—	—

Tabelle 6.1.: Die Definition der erweiterten Merkmale E_1 , E_2 , E_3 , und E_4 : An den Positionen $x = 6, 32, 47, 74$ werden jeweils verschiedene Wellenzahlen $\{k_m \dots k_n\}$ zu einem Intervall zusammengefaßt und innerhalb dessen gemittelt. Jeder Eintrag in einer der rechten fünf Spalten gibt die Definition eines Intervalls und somit ein Element des Merkmalsvektors an. Striche symbolisieren, daß kein Eintrag vorgenommen wird. Die Auswahl der Positionen x und Wellenzahlenintervalle $\{k_m \dots k_n\}$ wird durch Auswertung der korrelierten Regionen aus Abbildung 6.8 getroffen.

6.3.3.1. NMSE und MSE der Probeklassifikation

Der NMSE ist in Abbildung 6.10 zusammengefaßt. Für jede Kohonengitter-Geometrie ist wieder ein Graph abgebildet. Die NMSE's der Klassifikatoren aus Kapitel 6.2 sind zum Vergleich mit eingetragen.

Schlußfolgerungen, die aus der Abbildung gezogen werden können, sind im folgenden zusammengefaßt:

- Die besten Klassifikatoren der erweiterten Merkmale (E_1 und E_2) ergeben vergleichbare Klassifikationsfehler wie der beste Klassifikator der bisherigen Merkmale, dem „*Streifen-Spektrum-Intervall-10/100* $\times 1$ “. Der NMSE für den Klassifikator „*E2/10* $\times 10$ “ beträgt 0.13.
- Eine Auswertung des sehr stark korrelierten Bereichs bei $k = 4$ (siehe Abbildung 6.8) reicht ohne Hinzunahme von den anderen Wellenzahlen nicht aus. Die höheren Wellenzahlen, die nach Abbildung 6.8 einen kleineren Korrelationswert aufweisen, sind für die Klassifikation ebenso wichtig.
- Die Auswertung von mehreren Bildstreifen x innerhalb eines Klassifikators, wie es bei den erweiterten Merkmalen erfolgt ist, verringerte in diesem Fall nicht den NMSE. Jedoch wird dadurch zuverlässiger ein gutes Ergebnis erlangt. Bei der Verwendung nur eines Streifens hing die Klassifikationsqualität stark von der Auswahl des Streifens ab (z.B. bei *Streifen-Spektrum-(Intervall)-10* und *-70*).

Den MSE und damit die Wahrscheinlichkeit einer Fehlklassifikation (siehe Kapitel 6.2.4.3) erhält man wiederum annähernd durch die Skalierung der Ordinate mit der Varianz der Notenklassen $\sigma^2 \approx 1.5$. Damit erhält man für den Klassifikator „*E2/10* $\times 10$ “ einen Wert $MSE = 0.20$. Das entspricht einer erfolgreichen Klassifikationsquote von 80 %.

6.3.3.2. Die Verwechslungsmatrix der Probeklassifikationen

In Abbildung 6.11 ist die Verwechslungsmatrix des Klassifikators eingetragen, der bezüglich des NMSE am besten klassifiziert hat, dem „*E2/10* $\times 10$ “.

6.3. Weiterentwicklung der Merkmale

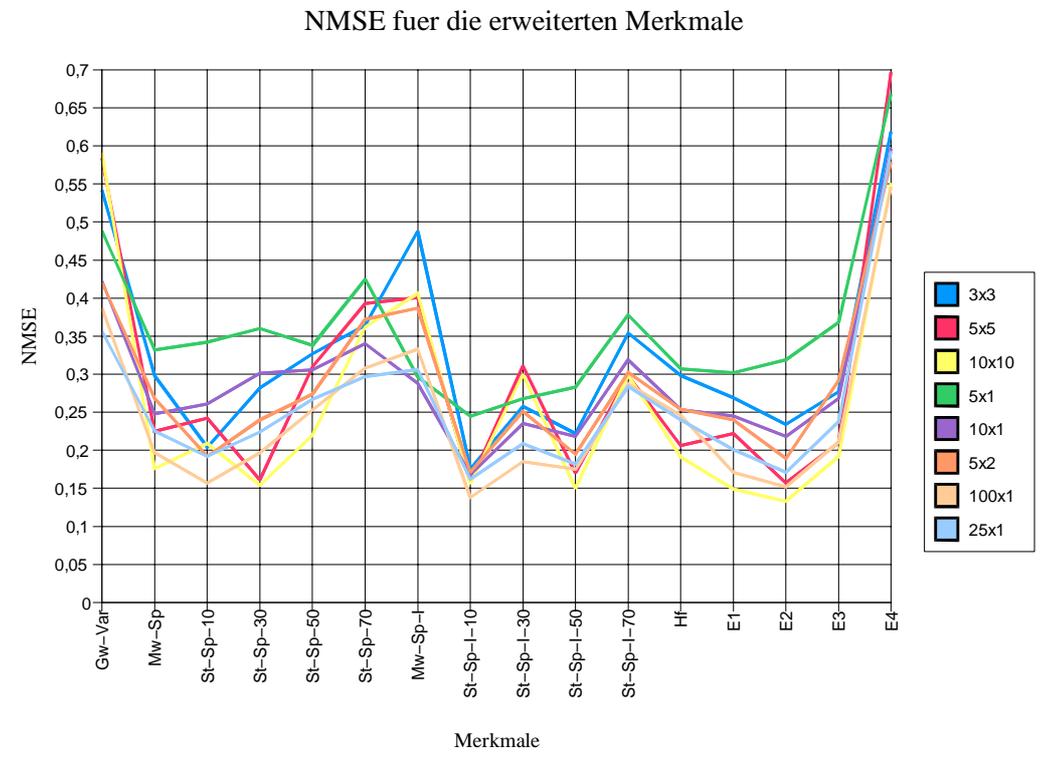


Abbildung 6.10.: Das Klassifikationsergebnis NMSE für die erweiterten Merkmale E_1 , E_2 , E_3 und E_4 . Zum Vergleich sind die NMSE's der Klassifikatoren der ersten Merkmale mit eingetragen. Der Klassifikator „ $E_2/10 \times 10$ “ liefert mit dem Wert $NMSE = 0.13$ das beste Ergebnis.

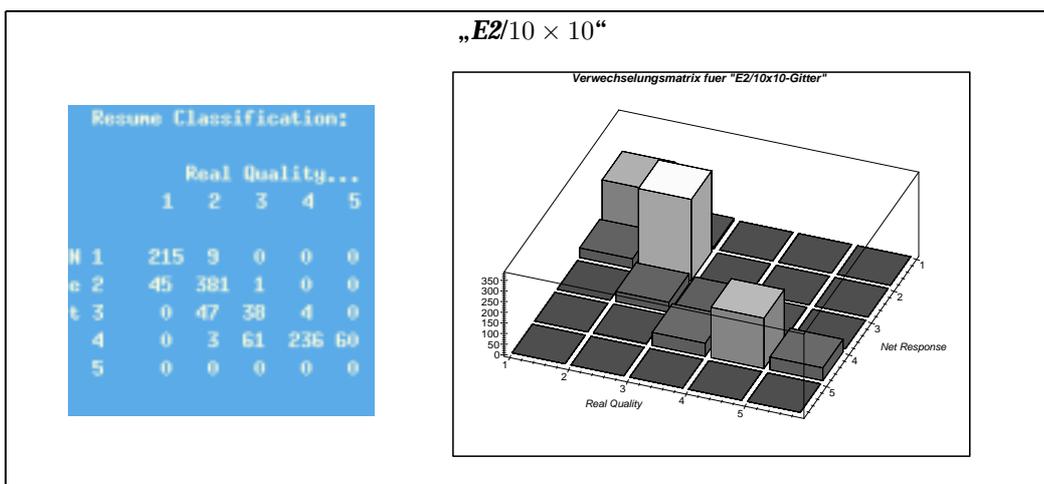


Abbildung 6.11.: Verwechslungsmatrix für den Klassifikator „ $E_2/10 \times 10$ “, links als Zahlenmatrix, rechts als Balkendiagramm.

6. Merkmalsextraktion

Sie enthält ähnliche Einträge wie die des „*Streifen-Spektrum-Intervall-10/100 × 1*“. Die Probennähte der Klassen 2 und 4 werden am zuverlässigsten klassifiziert. Testbeispiele der Sollklasse 5 werden wiederum in die Klasse 4 eingeordnet. Desweiteren betragen eventuelle Klassifikationsfehler höchstens eine Notenklasse.

6.3.3.3. Untersuchung der beim Training entstandenen Kohonenkarte

Eine Struktur der Kohonenkarte, die sich beim Training mit dem „E2/10 × 10“-Klassifikator entwickelt hat, zeigt Abbildung 6.12. Es sind wiederum links oben die Neuronenantworten, rechts oben die Sollklassen der Testbeispiele und unten ein weiteres Mal die Sollklassen der Testbeispiele, diesmal aber durch ihre Nahtserienzugehörigkeit gekennzeichnet, aufgetragen.

Auch hier gelten die gleichen Schlußfolgerungen wie bei den Merkmalen aus Kapitel 6.2:

- Die Klassenstruktur (linkes oberes Schaubild) weist eine gute Monotonieeigenschaft auf und wieder haben sich nur wenige (zwei) Neuronen für die Klasse 5 gebildet.
- Die Testnähte fallen in den meisten Fällen in korrekte Regionen der Karte (siehe rechtes oberes Schaubild).
- Die Testbeispiele der roten und schwarzen Serie fallen hauptsächlich in andere Regionen der Karte als Testbeispiele der rosa Serie (siehe unteres Schaubild).

6.4. Zusammenfassung der Klassifikationsergebnisse

Die Klassifikation mit den zuerst gewählten Merkmalen hat gezeigt, daß schon durch einfache Methoden gute Klassifikationsergebnisse zu erzielen sind. Die korrekte Klassifikationsquote lag hier bei 80 %. Ebenfalls wurde gezeigt, daß ein Kohonennetz fähig ist, die Welligkeiten in einer geeigneten Struktur zu repräsentieren.

Durch die Untersuchungen bei der Erweiterung der Merkmale ist einsichtig geworden, welche Regionen im k - x -Raum zu einer guten Klassifikationsleistung beitragen. Der Klassifikationsfehler konnte mit den erweiterten Merkmalen zwar nicht entscheidend verbessert werden, jedoch besteht die Hoffnung, daß durch eine Ausweitung der Beispielstreifenmenge hier weitere Fortschritte erfolgen können.

Ein zukünftiges Vorgehen für die Verbesserung der Merkmale könnte darin bestehen, den k - x -Raum intensiver auf geeignete Stellen zu untersuchen. Dies kann durch unterschiedliche Ansätze geschehen:

- Durch einfaches Austesten kann versucht werden, die signifikanten Stellen des k - x -Raums zu detektieren.
- Durch eine Auswertung der *Autokorrelation* $A(k, x)$ kann Information über untereinander korrelierte Spektren $\|X(k_i, x_i)\|$ gewonnen werden. Mit diesem Wissen kann eine Zusammenlegung der Spektren in ein Intervall gezielter vorgenommen werden.
- Der Korrelationskoeffizient von Fourier-Spektrum und Notenklassen kann klassenabhängig berechnet werden. Dadurch würde Aufschluß darüber gegeben werden, welche Positionen (k, x) die entscheidene Information über welche Notenklasse enthalten. Unter Zuhilfenahme der Verwechslungsmatrix könnten so gezielt Fehlklassifikationen für bestimmte Notenklassen verringert werden.
- Es kann versucht werden, die signifikanten Positionen (k, x) mit mathematischen Methoden zu berechnen. Zum Beispiel kann ein Verfahren benutzt werden, das eine feste Anzahl M von Gaußglocken $g_m(k, x) = (\eta_m(k, x), \sigma_m(k, x))$ im k - x -Raum so verschiebt, daß geeignete Positionen (k_i, x_i) für die Gaußglocken g_m gefunden werden, die im Anschluß mit der Gaußmaske gefaltet werden. Dies kann z.B. in einem „*simulated annealing*“- oder Gradientenabstiegsverfahren des Klassifikationsfehlers implementiert werden.

6.4. Zusammenfassung der Klassifikationsergebnisse

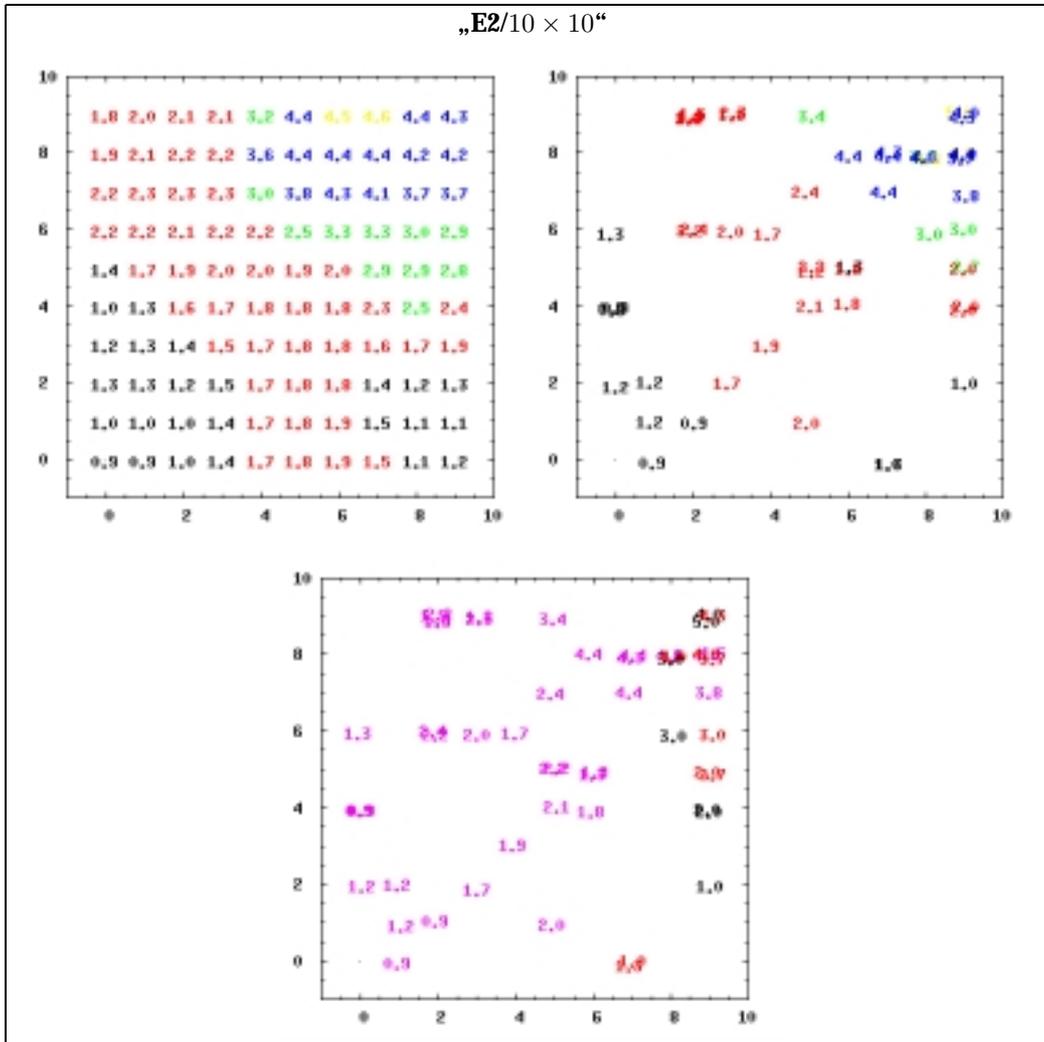


Abbildung 6.12.: Das Kohonen-Netz, wie es sich im Lernalgorithmus gebildet hat, für den Klassifikator „E2/10 × 10“: In dem linken oberen Bild sind die Ausgabewerte aller Neuronen an deren Position eingetragen. Die verschiedenen Farben symbolisieren die Zugehörigkeit der Neuronen zu den ganzzahligen Notenklassen 1, 2, 3, 4 und 5. Im rechten oberen Schaubild sind die Sollklassen der Testnähte an der Position eingetragen, die dem Siegerneuron des jeweiligen Klassifikationsschrittes entspricht. Idealerweise müßten sie Regionen der Karte zugeordnet werden, die ihrer Sollklasse entsprechen. Die Farben kodieren hier—in der gleichen Weise wie im linken Bild—die Sollklasse. Im unteren Bild sind die Sollklassen der Testbeispiele ein weiteres Mal an den entsprechenden Positionen eingetragen. Hier haben die Farben eine andere Semantik: Rosa, rote und schwarze Werte geben die Zugehörigkeit der Testbeispiele zu den rosa, roten bzw. schwarzen Nahtserien an. Für weitere Erläuterungen siehe [Abbildung 6.5](#).

6. Merkmalsextraktion

- Die zweite Ausgabe der Fourier-Transformation, die Phase, kann ergänzend bei der Merkmalsberechnung berücksichtigt werden.

7. Zusammenfassung und Ausblick

7.1. Zusammenfassung

In dieser Arbeit wurde die Realisierbarkeit einer computergestützten Qualitätskontrolle von textilen Nähten untersucht. Zu diesem Zweck wurde ein System entwickelt, welches die automatisierte, kameragestützte Klassifizierbarkeit von einem eingeschränkten Bereich von Textilien überprüft hat. Das erarbeitete System besteht aus einer *Aufnahmeapparatur*, einer *Bildpositioniereinheit*, einem *Nahtmerkmalsextraktor* und einem *neuronalen Netz*, welches zur Repräsentation der Klassenstruktur verwendet wurde.

Die Realisierbarkeit und Leistungsfähigkeit des System wurde anhand von *Probenähten* untersucht, welche in der Textilindustrie zur Einstellung von Nähmaschinenparametern Anwendung finden. Die Probenähte bestanden aus einfach gestalteten texturlosen Bekleidungstextilien. Das Kriterium für die Qualität der Probestreifen ist in der Hauptsache die Ausprägung von Welligkeiten auf der Stoffoberfläche.

Es wurde ein System zur *Bildaufnahme* erarbeitet, das die Probenähte für eine computergestützte Weiterverarbeitung digital erfassen kann. Dabei wurde gezeigt, daß dasjenige Bildaufnahmesystem, welches die Qualitätsinformation am besten einfängt, in den wesentlichen Eigenschaften einem Standard entspricht, der in der Textilindustrie bereits bei der Begutachtung von Probenähten Anwendung findet. Es ist so aufgebaut, daß die Kamera die vertikal hängenden Nahtbilder aus einer frontalen Position aufnimmt. Die Beleuchtungseinrichtung ist in einem Winkel von 20° zur Probestreifenebene oberhalb des Streifens angebracht.

Es wurde ein *Bildpositionierer* entwickelt, der schief bzw. nicht zentriert aufgenommene Nahtbilder nachträglich in der Position normiert. Sein logischer Aufbau besteht aus einem Nahtdetektor und einer Rotations-/Translationseinheit. Der Nahtdetektor wurde durch eine Kombination von einem Kantendetektor und einem auf der Hough-Transformation basierenden Geradenerkennungsverfahren realisiert. In der praktischen Anwendung ist es dem Bildpositionierer zuverlässig und genau gelungen, den Nahtverlauf in den Bildern zu detektieren und in die Bildmitte zu positionieren.

Für den *Merkmalsextraktor* wurden mehrere Typen von Merkmalen entwickelt und miteinander verglichen. Die erfolgreichsten Merkmale basieren auf einer Reihe von eindimensionalen Fourier-Spektren, die auf 1-pixel-breiten Bildstreifen längs zur Naht berechnet wurden.

Die mit dem in der Arbeit entwickelten Nahtklassifikator erzielten Ergebnisse weisen für die behandelten Probenähte eine korrekte Klassifikationsquote von 80 % auf. Die Klassifikationsdauer eines bereits aufgenommenen Nahtbildes betrug auf einem *Intel Pentium Pro 200 Doppel-Prozessor* ungefähr 1 Sekunde, was deutlich schneller ist als die von Fachkräften durchgeführte Begutachtung. Es ist zu erwarten, daß sich durch eine Erweiterung der Nahtbeispielmenge und einer eingehenderen Untersuchung des Merkmalsraumes der Klassifikationsfehler verringern wird und auch komplizierter gestaltete Probenähte (zum Beispiel mit Textur) erfolgreich klassifiziert werden können. Ideen zu einer Vorgehensweise zum Ausbau des Systems gibt der folgende Abschnitt.

7.2. Ausblick

Es gibt sowohl in textiltechnischer als auch in informations- und bildverarbeitender Hinsicht Aufgabenstellungen, deren Untersuchung in aufbauenden Arbeiten lohnenswert ist.

7. Zusammenfassung und Ausblick

Anwendungen für eine Qualitätskontrolle in der Textilindustrie liegen in folgenden, weiteren Gebieten:

- Zu einer universelleren Einsetzbarkeit des Systems ist es erstrebenswert, die Menge der klassifizierbaren Probenähte auszuweiten. In diesem Zusammenhang kann an die Klassifikation von Probestreifen, die eine Farb- bzw. Strukturtextur besitzen, gedacht werden.
- Es kann untersucht werden, ob die Einstellung der Nähmaschinenparameter durch eine fortlaufende, sich wiederholende Qualitätsbeurteilung eines Probestreifens vollautomatisch geschehen kann. Ein zu dieser Aufgabe zu entwickelndes System würde in einer Iterationsschleife die Qualität eines genähten Teilstücks des Probestreifens berechnen, danach die Parameter der Qualität entsprechend einstellen, die Qualität des neu genähten Teilstücks wieder berechnen usw., bis der Probestreifen eine ausreichende Qualität aufweist.
- Eine automatisierte Qualitätskontrolle ist auch bei der Überprüfung von Bekleidungsstücken in der Zwischen- und Endkontrolle denkbar. Hierbei kann man sich einerseits vorstellen, die Bekleidungsstücke durch eine fest installierte Kamera zu erfassen, andererseits durch eine kleine, mobile Handkamera, die zur Bildaufnahme entlang der Nähte bewegt wird.
- Beim Vernähen von Geweben mit Mustern kann überprüft werden, ob die Muster an der Naht bündig anschließen.

Ideen und Ansätze, die zur Lösung dieser Aufgabenstellungen beitragen können, sind im folgenden angeführt:

- Die Merkmalsextraktion für die bisher behandelten Probenähte kann in vielerlei Hinsicht ausgebaut werden. Stichpunktartig seien hier erwähnt: „*simulated annealing*“-Verfahren zur Merkmalsgenerierung, Ausnutzung von Korrelationen in den Merkmalen, Verwendung der Phase der Fourier-Transformation, u.a.
- Bei der Verwendung von Stoffen mit Textur kann Information über die Phasenverschiebung der Fourier-Transformation helfen, die durch die Textur hervorgerufenen Wellenzahlen zu filtern.
- Der Bildpositionierer kann auf das Aufspüren und Begradigen eines *krummen* Nahtverlaufs erweitert werden. Dies könnte eventuell durch eine stückweise Approximation der krummen Naht durch viele Teilgeraden geschehen.

A. Mathematische Methoden und verwendete Verfahren

A.1. Verfahren zur Maximierung der Grauwertvarianz bei der Bildaufnahme

Bei der in Kapitel 3.2.3 besprochenen Einstellung des Blendenwertes wird das Programm *avis* verwendet. Dieses Programm sorgt einerseits für die Gewinnung einer guten Bildqualität und andererseits für eine Helligkeitsnormierung der Aufnahmen unter den verschiedenen Stofftypen. Ausführliche Dokumentation zu *avis* befindet sich in [Kubisch, 1995]. In diesem Abschnitt wird dessen Idee und Arbeitsweise grob skizziert.

Als das Kriterium für die Einstellung der Blendengröße *Apertur* A betrachtet *avis* die Varianz des Grauwertistogramms σ_G^2 des Bildes. Diejenige Einstellung A_0 , unter der die größte Grauwertvarianz auftritt, besitzt den größten Kontrast [Kubisch, 1995] und bildet daher auch eine vernünftige Grundlage für die Helligkeitsnormierung:

$$A_0 = \operatorname{argmax}_A (\sigma_G^2(A))$$

Der Wert A_0 wird in einem Gradientenaufstiegsverfahren im 2-dimensionalen Raum der Blendenstellgröße A und der Grauwert-Varianz σ_G^2 ermittelt (siehe Abbildung A.1). Da die Varianzkurve keine Nebenmaxima besitzt, führt das Gradientenaufstiegsverfahren stets zu einem eindeutigen Wert für A .

A.2. Der Korrelationskoeffizient

Zur Generierung geeigneter Stoffstreifenmerkmale ist es hilfreich, im Fourier-Spektrum S nach Wellenzahlen k und Positionen x auf der Naht zu suchen, für die $S(x, k)$ und die Notenklasse N der Nähte „in Abhängigkeit zueinander“ stehen (vergleiche Kapitel 6.3). Für diesen Zweck wird der Korrelationskoeffizient verwendet, dessen Definition in diesem Kapitel erläutert wird.

Die „Abhängigkeit“ zweier statistische Größen X und Y untereinander wird mathematisch durch die Kovarianz

$$\operatorname{Cov}(X, Y) = \langle \tilde{X} \cdot \tilde{Y} \rangle$$

beschrieben, wobei $\tilde{X} = X - \eta_X$ und $\tilde{Y} = Y - \eta_Y$ die zu den Mittelwerten η_X und η_Y verschobenen Größen von X und Y sind. Die eckigen Klammern beschreiben einen Mittelungsprozeß.

Mit Hilfe der Cauchy-Schwarz'schen Ungleichung kann gezeigt werden [Berger, 1993], daß

$$|\operatorname{Cov}(X, Y)| \leq \sigma_X \sigma_Y \quad (\text{A.1})$$

$\sigma_{X,Y}$ sind dabei die Quadratwurzeln der Varianzen von X und Y . Die Gleichheit in (A.1) tritt genau dann auf, wenn X und Y in linearem Zusammenhang stehen,

$$Y = aX + b \quad (a, b \in \mathbb{R})$$

X und Y hängen in diesem Fall also mit der Wahrscheinlichkeit $P = 1$ direkt voneinander ab.

A. Mathematische Methoden und verwendete Verfahren

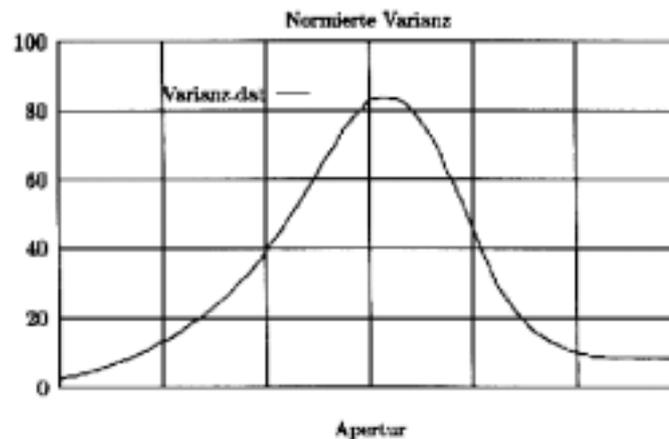


Abbildung A.1.: Der Verlauf der Grauwert-Varianz als Funktion der Blendenstellgröße *Apertur* A . Auf der Abszisse ist die *Apertur* (Blendenöffnung) aufgetragen, auf der Ordinate die *Grauwert-Varianz*. Für den linken Rand ist die Blende geschlossen, für den rechten maximal geöffnet. Das Maximum der Varianzkurve wird in einem Gradientenaufstiegsverfahren ermittelt. (Abbildung aus [Kubisch, 1995])

Die Beschränktheit der Kovarianz (A.1) motiviert die Definition eines normierten Maßes für die *Korrelation* zwischen X und Y , die des *Korrelationskoeffizienten* ρ_{XY}

$$\rho_{XY} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \quad (\text{A.2})$$

Der Korrelationskoeffizient ρ_{XY} hat folgende Eigenschaften

1. ρ_{XY} ist eine zwischen -1 und 1 normierte Größe:

$$-1 \leq \rho_{XY} \leq 1$$

2. Es gilt

$$\rho_{XY} = 0 \Leftrightarrow \text{Cov}(X, Y) = 0$$

Ist $\rho_{XY} = 0$, so heißen X und Y *unkorreliert*.

3. Ist $\rho_{XY} = \pm 1$, dann besteht ein linearer Zusammenhang zwischen X und Y

$$\rho_{XY} = \pm 1 \Leftrightarrow Y = aX + b \quad (a, b \in \mathbb{R})$$

Für $\rho_{XY} = -1$ haben \tilde{X} und \tilde{Y} stets das entgegengesetzte Vorzeichen. Man sagt dann, sie sind *antikorreliert*.

Der Korrelationskoeffizient bietet damit die Möglichkeit, das Fourier-Spektrum $S(x, k)$ auf geeignete Regionen für die Merkmalsgenerierung zu untersuchen. Ein Wert $|\rho_{SF}(x_0, k_0)| \approx 1$ bedeutet dabei eine hohe Korrelation von Spektrum und Note und motiviert daher die Verwendung von $S(x_0, k_0)$ als Notenmerkmal.

Danksagung

An dieser Stelle möchte ich einen besonderen Dank an Prof. Helge Ritter für die interessante Aufgabenstellung und die motivierende Unterstützung durch Anregungen, Ideen und Gespräche aussprechen.

Besonderer Dank geht auch an Gunther Heidemann, der mir in allen meinen Fragen mit Ideen, Anregungen, Rat und Tat zur Seite stand.

Bedanken möchte ich mich bei Robert Rae, der mir eine Einführung in die Bildaufnahme mit dem „Kamerakopf“ gegeben hat und bei Problemen stets zur Hilfe stand. Bei Robert möchte ich mich auch für die Bereitstellung des Programms *avis* zur automatischen Blendenregelung bedanken.

Für die Hilfe bei Problemen mit der Kamera gilt mein Dank ebenfalls Jan Jokusch.

Mein Dank gilt auch dem IFN, dort ganz besonders Frau Donath und Herrn Tetzlaff, für die Bereitstellung der Stoffproben und für die Beantwortung meiner Fragen in nähtechnischen Angelegenheiten.

An Jörg Ontrup geht mein Dank für die Bereitstellung des Codes für die Hough-Transformation.

Besonders bedanken möchte ich mich auch bei Björn Büsing, Axel Farchmin, Bernd Korte, Michael Krause, Guido Menkhaus, Tim Nattkemper, Jörg Ontrup, Dirk Schwammkrug und Sascha Ziehn, die mir bei der täglichen Arbeit mit Tips und Hilfen und mit Korrekturen der Arbeit stets zur Seite standen und in deren Gegenwart die Erstellung dieser Arbeit sehr angenehm war.

Ein herzlicher Dank gilt besonders meinen Eltern, die mich immer unterstützt und mir das Studium erst ermöglicht haben.

Literaturverzeichnis

- [Bässmann and Besslich, 1991] Bässmann, H. and Besslich, P. W. (1991). *Bildverarbeitung Ad Oculos*. Springer Verlag. [4](#)
- [Berger, 1993] Berger, M. A. (1993). *An Introduction to Probability and Stochastic Processes*. Springer Verlag, New York. [A.2](#)
- [Davies, 1990] Davies, E. (1990). *Machine Vision*. Academic Press Limited. [4](#), [4.1.2](#)
- [DIS, 1981] DIS (1981). *Draft International Standard, ISO/DIS 7770; Textiles—Method of test for evaluating the appearance of seams in durable press products after domestic washing and drying*. Draft International Standard, ISO/DIS 7770. [3.1.1](#), [3](#)
- [Doering, 1975] Doering, A. L. (1975). *Grund- und Fachwissen Bekleidung, Maschinenkunde*. Verlag Dr. Felix Büchner – Verlag Handwerk und Technik G.m.b.H. [2.2](#)
- [Ferd. Schmetz G.m.b.H, 1975] Ferd. Schmetz G.m.b.H (1975). *Taschenbuch der Nähtechnik*. Ferd. Schmetz G.m.b.H. [2.3](#), [2.2](#)
- [Jähne, 1993] Jähne, B. (1993). *Digitale Bildverarbeitung, 3. Auflage*. Springer-Verlag.
- [Kohonen, 1984] Kohonen, T. (1984). Self-organization and associative memory. In *Springer Series in Information Sciences 8*. Springer Verlag Heidelberg. [5.1](#)
- [Kubisch, 1995] Kubisch, R. (1995). Aktives Sehen mittels eines binokularen Kamerakopfes: Ein Ansatz auf der Grundlage neuronaler Netze. Master's thesis, Universität Bielefeld, Technische Fakultät. [3.2.3](#), [A.1](#), [A.1](#)
- [Press et al., 1992] Press, H., Teukolsky, S., Vetterling, W., and Flannery, B. (1992). *Numerical Recipes*. Cambridge University Press. [3.2.2](#), [6.2.1](#)
- [Ritter et al., 1992] Ritter, H., Martinetz, T., and Schulten, K. (1992). *Neuronale Netze*. Addison-Wesley, München. [5.1](#), [5.2](#)
- [Schmuker, 1964] Schmuker, M. (1964). *Garne, Stoffe und Werkzeuge in unserer Hand*. Verlag Burgbücherei Wilhelm Schneider. [2.1](#)
- [Schwartz, 1970] Schwartz, M. (1970). *Information, Transmission, Modulation, and Noise*. McGraw-Hill, San Francisco. [6.2.1](#)
- [Wunsch and Schreiber, 1992] Wunsch and Schreiber (1992). *Stochastische Systeme, 3. Auflage*. Springer Verlag, Berlin.