

Weitere Anstrengungen sollten die Erhöhung der Anzahl der Texturen eines Bildes im Blickpunkt haben. Um Aussagen über die unterschiedliche Leistungsfähigkeit verschiedener Wavelets machen zu können, sollten Bilder mit Texturen unterschiedlicher Größe untersucht werden.

6 Danksagung

Diese Arbeit wurde ermöglicht durch die Unterstützung der Deutschen Telekom im Rahmen des Forschungsprojektes KAMEDIN. Ein besonderer Dank gilt Prof. Markus Groß für die Anregungen zu dieser Arbeit sowie Lars Lippert und Rolf Koch für die Implementierung der Wavelettransformation bzw. der Kohonen-Feature-Map.

7 Literatur

- [1] A. Akansu, R.A. Haddad, "Multiresolution Signal Decomposition", Academic Press Inc., Boston San-Diego New York, 1992
- [2] P. Brodatz, "Textures-A Photographic Album for Artists and Designers", Dover, New York, 1966
- [3] C. Busch, M. Eberle, "Morphological Operations for Color-Coded Images", Computer Graphics Forum, Tagungsband der EUROGRAPHICS'95, erscheint 1995
- [4] C. Busch, M. Groß: "Interactive Neural Network Texture Analysis and Visualization for Surface Reconstruction in Medical Imaging". Computer Graphics forum, Vol.12, No.3, pp.C49-C60, 1993
- [5] T. Chang, C.C.J. Kuo: "Texture Analysis and Classification with Tree-Structured Wavelet Transform", IEEE Transactions on Image Processing, Vol. 2, pp. 429-441, 1993
- [6] C. K. Chui: "An Introduction to Wavelets", Academic Press Inc., Boston San-Diego New York, 1992
- [7] K. Etemad, R. Chellappa: "Separability based Tree Structured Local Basis Selection for Texture Classification". IEEE-ICIP, pp.441-445, 1994
- [8] M. Groß, R. Koch, L. Lippert, A. Dreger: "Multiscale Image Texture Analysis in Wavelet Spaces". IEEE-ICIP, pp.412-416, 1994
- [9] M. Groß, F. Seibert: "Visualization of Multidimensional Image Data Sets Using a Neural Network". The Visual Computer 10, pp.145-159, Springer Verlag, 1993
- [10] R.M. Haralick: "Statistical and Structural Approaches to Texture". Proceedings of the IEEE, Vol.67, No.5, pp. 786-804, 1979
- [11] B. Julesz: "Textons, the Elements of Texture Perception and their Interactions". Nature, Vol. 290, pp. 91-97, 1981
- [12] T. Kohonen: "The Self-Organizing Map". Proceedings of the IEEE, Vol.78, No.9, pp.1464-1480, 1990
- [13] S.G. Mallat: "A Theorie for Multiresolution Signal Decomposition: The Wavelet Representation", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 11, pp 674-693, 1989
- [14] P. Palisson, N. Zegadi, F. Peyrin, R. Unterreiner: "Unsupervised Multiresolution Texture Segmentation using Wavelet Decomposition". IEEE-ICIP, pp.625-629, 1994
- [15] M. Schmerer: "Untersuchungen zur Eignung der Wavelettransformation für die Texturanalyse", Diplomarbeit an der TH-Darmstadt, FB 20, 1994
- [16] M. Vetterli: "Wavelets and Filter Banks: Theory and Design", IEEE Transactions on Signal Processing, Vol.40, pp. 2207-2231, 1992
- [17] M. Werman, S. Peleg: "Min-max operators in texture analysis". IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-7 No. 4, 1985

sen oder die Einbindung eines Fuzzy-Entscheids möglich, der beispielsweise unterschiedliche Klassifikationsgüten der K Klassifikationsverfahren berücksichtigt.

4.3. Dritte Stufe: Morphologische Nachbearbeitung

In einer dritten Stufe der Texturanalyse wird das verknüpfte Ergebnisbild mittels morphologischer Operationen nachbearbeitet. Hierzu wurden die in [3] definierten Operationen für farbkodierte Bilder verwendet. Sie sind insbesondere in der Lage ein klassensensitives Postprocessing auf Klassifikationsresultaten zu ermöglichen. Im einzelnen wurden folgende Operationen angewandt. Erstens ein relatives Opening, gefolgt von einer bedingten Dilatation zum Entfernen kleiner unzusammenhängender Bereiche. Zweitens ein Closing zur Glättung des Bildes. Drittens ein Opening gefolgt, von einer bedingten Dilatation zum Herausfiltern der Hauptbereiche, d.h. der Texturbereiche. Viertens ein Closing mit anschließenden Dilatationen zum Auffüllen undefinierter Teilgebiete. Fünftens eine Verschneidung mit dem Eingangsbild für das Postprocessing (Ergebnisbild V). Sechstens ein Closing und anschließende Dilatation zum Auffüllen aller undefinierten Bereiche. Abschließend wird durch eine Glättungsoperation die Texturbereichskante bereinigt. Das so erzielte Endergebnisbild P ist in Abbildung 4.3 zu sehen. Festzuhalten ist, daß die Fehlerrate der Generalisierung mittels der beschriebenen Nachbearbeitung auf bis zu 1.5 % reduziert werden kann. Verbleibende Fehlklassifikationen sind im Bereich der Texturkante lokalisiert.

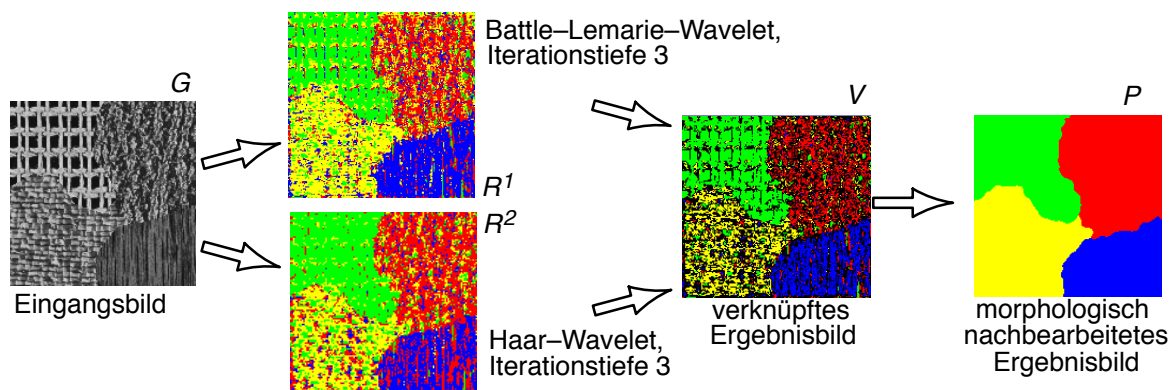


Abb. 4.3: Beispiel einer dreistufigen Texturanalyse

Anzumerken ist noch, daß die gewählten morphologischen Operationen allgemeiner Natur sind, d.h. daß sie nicht für jedes Eingangsbild neu festgelegt werden müssen. Das Verfahren ist damit sowohl von der Art der Texturen als auch vom Verlauf der Texturgrenzen unabhängig.

5 Bewertung und Ausblick

Die in diesem Beitrag vorgestellte Methode stellt einen vielversprechenden Ansatz für die Texturanalyse dar. Für die Bildklassifikation ergeben sich sehr gute Ergebnisse. Es hat sich gezeigt, daß die Art der Texturen eine eher geringe Rolle für die Fehlerrate spielt. Die generalisierende Klassifikation von 4-Textur Brodatz Bildern in Verbindung mit der zweiten und dritten Stufe der vorgestellten Texturanalysepipeline liefert Ergebnisse, die die Texturen nahezu optimal detektieren. Der vorgestellte Ansatz erfüllt damit die gestellten Forderungen hinsichtlich der sicheren Zuordnung von Texturbereichen **und** sauberer Detektion der Texturkanten. Der Entwurf einer dreistufigen Texturanalysepipeline hat sich insofern im Hinblick auf eine Qualitätssteigerung der Klassifikation bewährt. Für den praktischen Einsatz im Bereich der Bildanalyse ergeben sich jedoch Einschränkungen. Zum einen wächst durch k -malige Berechnung der Einzelergebnisse der Berechnungsaufwand, zum anderen sind die bei dieser Untersuchung verwendeten Texturmuster sowohl hinsichtlich ihrer Größe als auch in der Anzahl der zu trennenden Muster mit den Anforderungen der Praxis nicht vergleichbar.

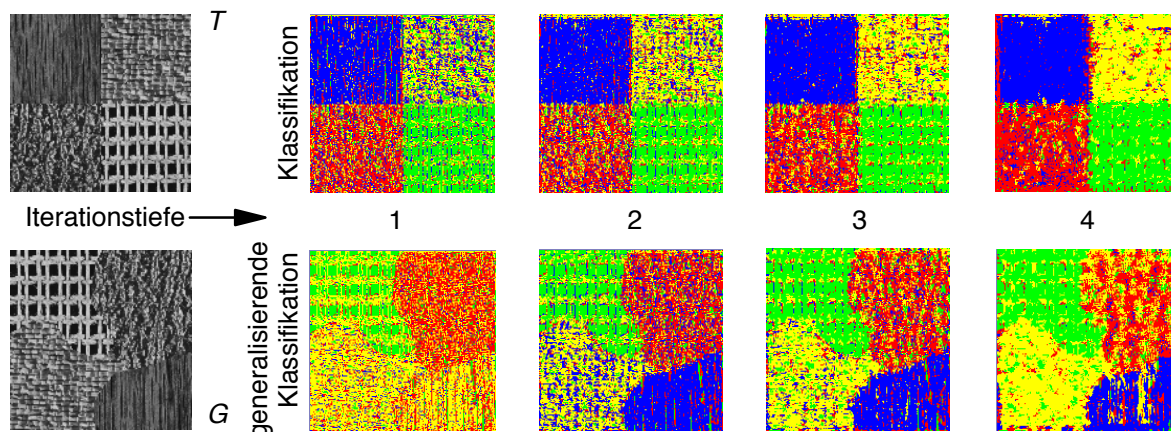


Abb. 4.1: Klassifikation und generalisierende Klassifikation bei unterschiedlichen Iterationstiefen der WT

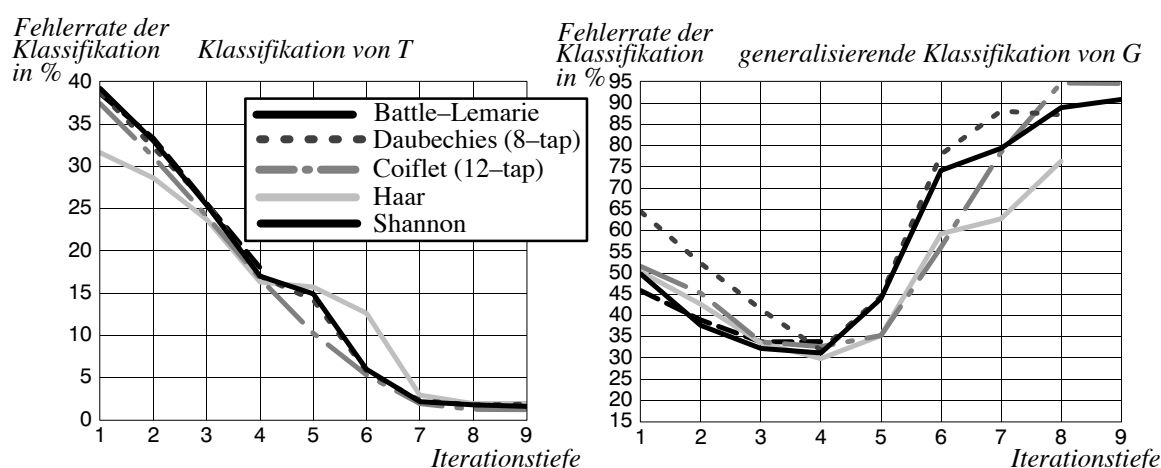


Abb. 4.2: Fehlerraten der Klassifikation in Abhängigkeit von der Iterationstiefe

den dazu multiple Waveletbasen verwendet. Grundsätzlich ist die Verknüpfung von mehreren Basiswavelets aus den unterschiedlichen Iterationstiefen 2, 3 oder 4 sinnvoll, sofern diese Basiswavelets unterschiedliche Eigenschaften aufweisen (vgl. Kapitel 2.2.). Für die hier gezeigten Ergebnisse wurde das Haar-Wavelet, sowie das Battle-Lemarie-Wavelet ausgewählt. Mit diesen wurde die WT berechnet und nach der in Kapitel 3 dargestellten Vorgehensweise Einzelresultate ermittelt.

Für die Berechnung eines Verknüpfungsbildes V wird eine Verknüpfungsregel der Einzelergebnisse R^k aufgestellt:

$$v_{xy} = \begin{cases} class(r_{xy}^1) & \text{if } class(r_{xy}^1) = \dots = class(r_{xy}^k) \\ \text{undefined} & \text{else} \end{cases} \quad (4.1)$$

Dabei ist v_{xy} ein Pixel des Verknüpfungsbildes V . Semantisch kann diese Regel folgendermaßen formuliert werden:

Setze im Verknüpfungsbild ein Pixel genau dann, wenn sich bei der Klassenzuordnung dieses Pixels in den Resultaten R^k alle K Klassifikatoren einig waren. Andernfalls markiere das Pixel als undefiniert.

Die Abbildung 4.3 zeigt ein verknüpftes Ergebnisbild V . Korrekt klassifizierte Pixel erhalten dadurch einen hohen Sicherheitsgrad. Durch die relativ strenge Verknüpfungsregel bleiben etliche Pixel im undefinierten Klassenzustand. Vakante Pixelpositionen sind schwarz visualisiert. Alternativ zur Regel in Formel 4.1 ist auch ein Maximumentscheid zwischen den einfließenden Klas-

line dar. In der zweiten Stufe wird aus diesen nach einer Verknüpfungsregel das Verknüpfungsergebnis V berechnet.

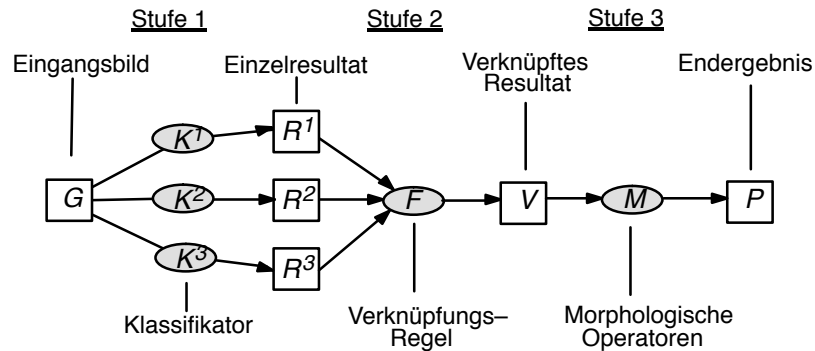


Abb. 3.2: Dreistufige Texturanalysepipeline

Die Ergebnisse im nächsten Kapitel werden zeigen, daß eine Verknüpfung verschiedener Einzelresultate gegebenenfalls zu einem Ausdünnen der geschlossenen Texturbereiche führt. Dieser Umstand wird durch ein abschließendes Postprocessing in einer dritten Stufe kompensiert. Dazu wurde ein morphologisches Postprocessing eingesetzt, das klassensensitiv die Regionenbereinigung eines Klassifikationsresultates durchführt [3].

4 Ergebnisse

Für die Untersuchungen wurden die 512x512 Pixel großen Eingangsbilder T und G mit den Brodatztexturen D20, D24, D68 und D84 generiert (vgl. Abbildung 4.1). Erste Untersuchungen gingen der Frage nach, in wie weit die Klassifikationsgüte von den im Eingangsbild verwendeten Texturen abhängig ist. Dazu wurden 6 verschiedene Bilder mit insgesamt 12 verschiedenen Brodatztexturen mit unterschiedlichen Eigenschaften (grobe/feine/regelmäßige/unregelmäßige Strukturen; visuell ähnliche Texturen benachbart angeordnet) erstellt. Als Ergebnis ist festzuhalten, daß sich die Fehlerraten der Klassifikationen (bei einer Ausnahme mit 4% Abweichung) nur um *ca.* 1% voneinander unterscheiden. Die Art der verwendeten Texturen spielt also für die Klassifikation mit dem hier verwendeten dreistufigen Verfahren keine wesentliche Rolle. Ähnliche Aussagen sind in [5] zu finden.

4.1. Erste Stufe: Klassifikation und generalisierende Klassifikation

Die Abbildung 4.1 zeigt die Klassifikation des zum Training des Klassifikators verwendeten Eingangsbildes T sowie eine generalisierende Klassifikation des Eingangsbildes G , die mit dem Battle-Lemarie-Wavelet erzielt wurden. Die einzelnen Resultate korrespondieren zu unterschiedlichen Iterationstiefen der Waveletdekomposition des Eingangsbildes.

Bei der Beurteilung der in Abbildung 4.1 gezeigten Einzelresultate muß man feststellen, daß zwar die Detektion der Texturkante zwischen den jeweiligen Texturbereichen gelungen ist, die Zuordnung eines einzelnen Pixels innerhalb des Texturbereichs zur richtigen Texturklasse nur mit einer Wahrscheinlichkeit von 70% möglich ist. Dieser visuelle Eindruck einer "verrauschten" Klassifikation wird durch die quantitative Auswertung in Abbildung 4.2 belegt. Solange die Zuordnungswahrscheinlichkeit jedoch deutlich über 50% liegt, ist eine sichere Zuordnung des gesamten Texturbereiches zur richtigen Klasse möglich, wie die Kapitel 4.2. und 4.3. zeigen werden. In Übereinstimmung mit [5] ist ersichtlich, daß die signifikanten Informationen der WT in den mittleren Frequenzkanälen liegen, d.h. insbesondere die Koeffizienten aus den mittleren Iterationstiefen 3 und 4 beschreiben die eigentlichen Textureigenschaften.

4.2. Zweite Stufe: Verknüpfung klassifizierter Ergebnisbilder

In der zweiten Stufe der Texturanalysepipeline aus Abbildung 3.2 werden die Informationen verschiedener Einzelresultate in einem Verknüpfungsbild zusammengetragen. In dieser Arbeit wur-

3 Die dreistufige Texturanalyse

Die Merkmalsextraktion ermittelt als zentrales Modul in der Texturanalysepipeline (siehe Abbildung 3.1) die signifikanten Merkmale eines Eingangsbildes. Im konkreten Fall führt dieses Modul unter Verwendung eines ausgewählten Basiswavelets eine Dekomposition des Eingangsbildes durch. Die Vorgehensweise der Zerlegung sowie die verwendeten Basisfunktionen sind im folgenden Kapitel beschrieben. Durch bilineare Interpolation zwischen den lokalisierten Koeffizienten im Frequenzraum kann somit für jede Pixelposition (xy) des Eingangsbildes E ein Merkmalvektor gewonnen werden, der das Eingangssignal beschreibt. Dies ist ausführlich in [8] erläutert. Eine nachgeschaltete Normierung bewirkt die Skalierung des Merkmalraumes, damit eine korrekte Abstandsberechnung durch Gleichgewichtung der einzelnen Komponenten der Merkmalvektoren erzielt wird. In [14] wurde in diesem Zusammenhang eine frequenzabhängige Wichtung der Komponenten während der Trainingsphase vorgeschlagen. Die berechneten Merkmalvektoren bilden den Datensatz für das Training eines Klassifikators, wobei konkret die selbstorganisierende Kohonen-Feature-Map [12] eingesetzt wurde. Der Einsatz einer 3D-Kohonen-Feature-Map in Verbindung mit einer nachgeschalteten Vektorquantifizierung (LVQ) wurde bereits in [9] und [4] ausführlich beschrieben. Die Zuweisung der Klasseninformation erfolgt dabei durch Auswertung der Klasseninformation aus den Trainingsgebieten (Abbildung 3.1a).

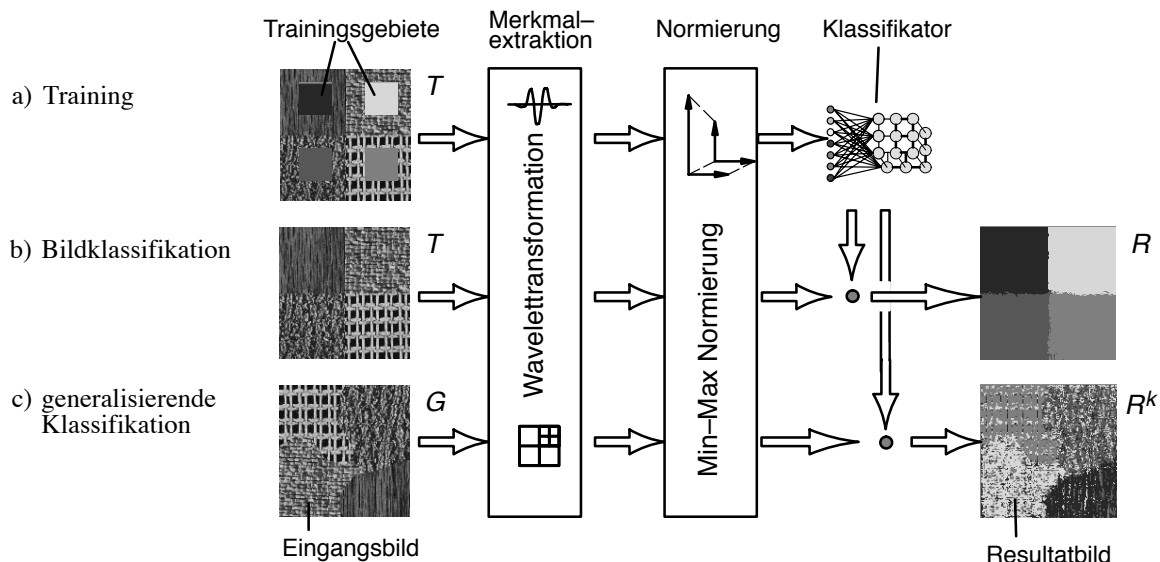


Abb. 3.1: Erste Stufe der Texturanalysepipeline

Die *Bildklassifikation* des Trainingsbildes T (siehe Abb. 3.1b) verwendet den auf den Trainingsdatensatz angepassten Klassifikator zur Klassifikation des gesamten Bildes. Die Merkmalvektoren werden dabei aus der gleichen Zerlegungspyramide abgeleitet, die auch zum Training verwendet wurde. Die Abbildung 3.1c zeigt eine *generalisierende Klassifikation*, wobei die WT des Eingangsbildes G die Zerlegungspyramide für die Berechnung der Merkmalvektoren bereitstellt. Die unveränderte Kohonen-Map der Trainingsphase a) analysiert die Merkmalvektoren und liefert ein Resultatbild R . Dieses Resultat beruht auf den besonderen Eigenschaften des verwendeten Basiswavelets B^k .

Sollen nun die Eigenschaften multipler Basiswavelets oder, allgemeiner formuliert, K unterschiedlicher Merkmalsextraktionsverfahren miteinander verknüpft werden, liegt eine Kombination der berechneten Merkmale im Merkmalvektor nahe. Ein derartiges Vorgehen in Verbindung mit anschließender Haupt-Komponenten-Transformation zur Dekorrelation der Merkmale hat sich jedoch in Voruntersuchungen nicht bewährt. Weitaus vielversprechender ist es, den Output von multiplen Klassifikatoren miteinander zu verknüpfen. Die zum Eingangsbild G berechneten Resultatbilder R^k (mit $k=1, \dots, K$) stellen dabei nur ein Zwischenresultat in der Texturanalysepipe-

velets konstruierbar. Die Waveletkoeffizienten sind somit nur von der Wahl des Basiswavelets abhängig. Für ausführlichere Darlegungen (Zusammenhang zwischen WT und Multiresolution Approximation, Erweiterung auf 2D-Signale) sei auf [1], [6] bzw. [13] verwiesen.

2.1. Berechnung der Waveletkoeffizienten

Die effiziente Berechnung der Koeffizienten der orthogonalen Waveletrepräsentation gelingt mittels des Mallat-Algorithmus [13]. Dabei wird ein 2D-Signal sukzessive in drei Hochpaßsignale (Detailsignale) und eine Approximation mit halbiertter Auflösung zerlegt. Abbildung 2.1 veranschaulicht das Berechnungsschema. H (Hochpaßfilter) und L (Tiefpaßfilter) bezeichnen ein QMF-Filterpaar, mit welchem die WT implementiert werden kann. Die Eigenschaften des Basis-Wavelet sind dann durch die Wahl des QMF-Filterpaares bestimmt.

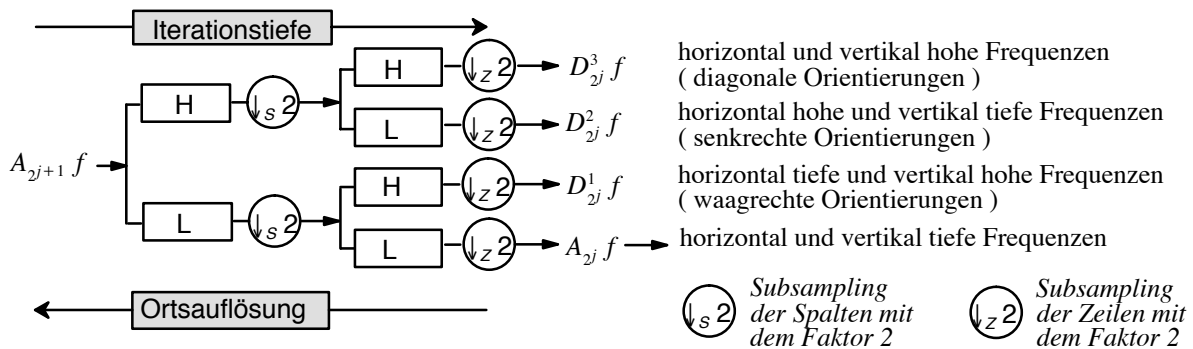


Abb. 2.1: Signalzerlegung während eines Iterationsschrittes bei einem 2D-Signal

Die anwendungsbezogenen Aspekte der Berechnung sind z.B. in [13] bzw. [16] nachzulesen.

2.2. Eigenschaften verschiedener Wavelets

Die in Abschnitt 4 benutzten Wavelets (Battle-Lemarie-, Coiflet-, Daubechies-, Haar- und Shannon-Wavelet) sind der Gruppe der orthogonalen Wavelets zuzuordnen, was gleichbedeutend mit einer nicht-redundanten Zerlegung des Signals ist. Diese Gruppe der Wavelets ist mit Ausnahme des Haar-Wavelets nicht symmetrisch. Weitere Eigenschaften sind die Trägerlänge (support) und die Regularität (Glattheit) eines Wavelets. Regularität ist formal als das maximale r von

$$|\hat{\phi}(\omega)| \leq \frac{c}{(1 + |\omega|)^{r+1}} \quad \hat{\phi}(\omega) \text{ ist die Fouriertransformierte von } \phi \quad (2.6)$$

definiert. Eine hohe Regularität eines Wavelets bedeutet, daß sowohl im Orts- als auch im Frequenzbereich eine gute Lokalisation ermöglicht ist. Abbildung 2.2 zeigt beispielhaft das Haar-




Abb. 2.2: Haar- und Battle-Lemarie-Wavelet im Orts- und Frequenzraum

Wavelet (sehr gute Lokalisation im Ortsraum, schwache Lokalisation im Frequenzraum) sowie das Battle-Lemarie-Wavelet (gute Lokalisation im Orts- und im Frequenzraum, *intermediate representation*).

IV: Generalisierende Klassifikation wird durch eine vollständige Texturanalyse realisiert. Dies bedeutet, daß das zu klassifizierende Bildmaterial nicht zum Training des Klassifikators verwendet wurde. In diesem Sinne wurde bei einer *generalisierenden Klassifikation* das zu klassifizierende Bild gegenüber dem Trainingsbild nicht nur hinsichtlich der Anordnung der Texturen im Bild verändert, sondern auch im Verlauf der Texturkanten.

Für *Bildklassifikation* und *generalisierende Klassifikation* bestehen zwei Forderungen: Zum einen muß die Texturkante sauber erkannt werden, um eine sichere Trennung der Texturbereiche zu ermöglichen. Zum anderen muß der Bereich eindeutig und korrekt einer vordefinierten Klasse zugeordnet werden. Erst wenn beide Forderungen erfüllt sind, ist das Verfahren zur Verarbeitung natürlicher Szenen wie etwa Satellitenbilder oder medizinischer Aufnahmen geeignet. Die besondere Problematik liegt dabei in der Detektion der Texturkante, da ein zur Auswertung eines Pixels definiertes Texturfenster dort verschiedenartige Texturen überdeckt.

Diese Arbeit behandelt die Texturanalyseproblematik im Sinne einer *generalisierenden Klassifikation*. Zur Merkmalextraktion wird dabei die Wavelettransformation verwendet. Die so gewonnene Klassifikation stellt jedoch nur die erste Stufe des Gesamtsystems dar. In einer zweiten Stufe werden die Ergebnisse von multiplen Waveletbasen miteinander verknüpft. Auf Grund der unterschiedlichen Eigenschaften der Basiswavelets werden jeweils unterschiedliche Charakteristika des zu verarbeitenden Signals erfaßt. Durch abschließendes Postprocessing auf den verknüpften Bildern werden die Texturbereiche in einer dritten Stufe bereinigt bzw. aufgefüllt.

Kapitel 2 erläutert die zur Merkmalextraktion eingesetzte Wavelettransformation und begründet die Auswahl der verschiedenen Basisfunktionen. Die vollständige dreistufige Texturanalysepipeline wird in Kapitel 3 vorgestellt. In Kapitel 4 werden die bei der Anwendung einer generalisierenden Klassifikation von Brodatztexturen erzielten Ergebnisse dargelegt und abschließend in Kapitel 5 bewertet.

2 Wavelettransformation

Die *diskrete WT* in ihrer dyadischen Form ist eine Abbildung $WT : L^2(\mathbb{R}) \mapsto L^2(\mathbb{R}^2)$ mit

$$WT_f^d(j, n) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{\infty} \psi_{jn}(t) f(t) dt \quad (2.1)$$

Dabei stellt ψ das *orthogonale Wavelet (basis wavelet)* dar, da (im dyadischen Fall)

$$\left(\frac{1}{\sqrt{(2^j)}} \psi_{2^j}(t - 2^{-j}n) \right)_{n \in \mathbb{Z}} \quad \left(\psi_{2^j}(t) = 2^j \psi(2^j t) \quad (\forall j \in \mathbb{Z}) \right) \quad (2.2)$$

eine Orthonormalbasis von O_{2^j} erzeugt (j bezeichnet den Dilatationsparameter, n den Translationsparameter). Dabei gilt (im Falle eines 1D-Signals)

$$V_{2^{j+1}} = V_{2^j} \oplus O_{2^j} \quad (2.3)$$

wobei $(V_{2^j})_{j \in \mathbb{Z}}$ die *Multiresolution Approximation* von $L^2(\mathbb{R})$ ist. Die Menge

$$\left(\frac{1}{\sqrt{2^j}} \cdot \phi_{2^j}(t - 2^{-j}n) \right)_{n \in \mathbb{Z}} \quad \left(\phi_{2^j}(t) = 2^j \phi(2^j t) \quad (\forall j \in \mathbb{Z}) \right) \quad (2.4)$$

mit der *Skalierungsfunktion* ϕ spannt dabei den Unterraum V_{2^j} auf. Wenn A_{2^j} den Approximationsoperator von f und $D_{2^j}f$ das Detailsignal bezeichnet, so ergibt sich in

$$(A_{2^{-j}} f, (D_{2^j} f)_{-j \leq j \leq -1}) \quad (2.5)$$

(1D-Signal) die *orthogonale Waveletrepräsentation* von f (*Waveletkoeffizienten*). Diese ist interpretierbar als eine Dekomposition des Signals in unabhängige Frequenzkanäle, welche eine – je nach Auflösung 2^j – gute Lokalisation von Ort bzw. Frequenz ermöglicht. Die Orts-Frequenzauflösung ist dabei nur durch die *Heisenberg'sche Unschärferelation* in Form von $\Delta f \cdot \Delta t \leq \frac{1}{4\pi}$ limitiert. Zudem sind die Waveletbasen durch Dilatation und Translation eines einzigen Basiswa-

Ein Verfahren zur Texturanalyse basierend auf multiplen Waveletbasen

Christoph Busch, Martin Schmerer

Zentrum für Graphische Datenverarbeitung e.V.
Wilhelminenstraße 7, D-64283 Darmstadt
E-mail: busch@igd.fhg.de

Zusammenfassung

Der Beitrag stellt ein Verfahren zur Texturanalyse vor, das auf der Wavelettransformation (WT) basiert. Die WT, deren prägnanteste Eigenschaft ihre gute Lokalisation im Orts- und im Frequenzbereich ist, stellt in Form einer Merkmalsextraktion den entscheidenden ersten Schritt innerhalb der Texturanalyse dar. Im Unterschied zu klassischen Verfahren der Texturanalyse werden die Ausgangsbilder dabei einer globalen WT, d.h. einer Anwendung auf das gesamte Bild, unterzogen. Ziel der Arbeit ist eine generalisierende Klassifikation von Brodatztexturen. Dieses Ziel wird durch das vorgeschlagene Verfahren erreicht, indem die Klassifikationsresultate, die durch Anwendung unterschiedlicher Basiswavelets erzielt werden, miteinander verknüpft und abschließend einer morphologischen Nachbearbeitung unterzogen werden.

1 Einleitung

Die Texturanalyse als klassisches Aufgabengebiet der Mustererkennung hat seit langem einen hohen Stellenwert innerhalb der Bildverarbeitung und Bilderkennung erreicht. Grundlegende Arbeiten im Gebiet der Texturanalyse von Julesz [11] und Haralick [10] waren geprägt durch ein statistisches Verständnis der Textur. Demzufolge wurden zur Texturerkennung Verfahren eingesetzt, die signifikante Merkmale aus der Statistik (1. bzw. 2. Ordnung) ableiteten. Mit der Entwicklung der Wavelettheorie wurde ein mathematisches Fundament für eine *Multiresolution Analysis* von Bilddaten gelegt [13], [16], die in der Folge durch eine Reihe von Arbeiten auf die Problematik der Texturanalyse angewandt wurde [5], [8], [14]. Dabei haben sich die besonderen Eigenschaften der Wavelettransformation, wie etwa der Erhalt des Lokalitätsbezugs im Frequenzraum, als sehr vorteilhaft erwiesen.

Als Quasi-Standard für die Beurteilung eines Texturanalyseverfahrens hat sich der Brodatz-Texturdatensatz [2] etabliert. In der Literatur finden sich jedoch die unterschiedlichsten Ansätze zur *Klassifikation* von derartigen Texturmustern, die bei genauerer Betrachtung der Verfahren nur schwer vergleichbar sind.

Zur Klärung dieser Problematik und zur Einordnung dieser Arbeit seien die folgenden Instanzen der Texturanalyse unterschieden:

I: Musterklassifikation löst die Zuordnungsproblematik eines kompletten Texturbildes oder Bildfensters. Derartige Ansätze trennen die gegebenen Muster (Bildfenster) in einen Satz von vordefinierten Klassen und erreichen dabei Erkennungsraten von nahezu 100% [5].

II: Bildsegmentierung erkennt im bearbeiteten Bild die darin enthaltenen verschiedenartigen Texturen. Sie umfaßt somit neben der Erkennung einer Textur auch die Detektion einer Texturkante. Es kommt hierbei lediglich auf die Abgrenzung von Bereichen unterschiedlicher Textur an, nicht jedoch auf deren Bedeutung [14]. Dies wird erst in der nächsten Instanz durch eine *Bildklassifikation* gelöst.

III: Bildklassifikation weist den abgegrenzten Bereichen eine vordefinierte Klasse zu [7]. Das zugrundeliegende Wissen ist dabei meist in Form von Trainingsgebieten definiert und wird im eingesetzten Klassifikator gespeichert.