

# Neuronale Netz-Detektion von Brustkrebs basierend auf einer Multi-Skalen Analyse

Anke Meyer-Bäse

Dep. of Electr. and Comp. Engineering,  
University of Florida, Gainesville FL 32611-6130, USA  
Email: anke@alpha.ee.ufl.edu

**Zusammenfassung** Die Aufgabe des neuronalen Radialbasisnetzes besteht darin, eine binäre Maske zu erzeugen, die eine Segmentierung von Massen (Verschattungen mit radiären Ausziehungen) direkt in der Mammographie-Aufnahme ermöglicht. Das neuronale Netz lernt Merkmalsvektoren, die Wavelet-Koeffizienten bei verschiedenen Auflösungen eines jeden einzelnen Pixel darstellen und entscheidet über die Wahrscheinlichkeit, ob ein Bildpunkt zu einem Bereich einer Masse gehört. Eine anschließende Fusion einer globalen Kontrastverstärkung des gesamten Bildes sowie einer lokalen Kontrastverstärkung der segmentierten Region unterstützen den Radiologen bei seiner Diagnose.

**Keywords:** Neuronales Netz, Wavelet, CAD-System, Brustkrebs

## 1 Einleitung

Rechnergestützte Interpretation von Mammographie-Aufnahmen war stets von besonderem Interesse für Forscher aus aller Welt, wobei sich ihre Zielsetzungen entweder auf die Erkennung von Clustern aus Mikrokalzifikationen oder die von Detektion von malignen Tumoren konzentrieren.

Verschattungen mit radiären Ausziehungen („spicular masses“) stellen eine der wichtigsten Formen von Läsionen dar, da die meisten Brustkarzinome das Aussehen einer Verschattung mit radiären Ausziehungen besitzen und deren Wahrnehmung äußerst schwierig ist, insbesondere wenn sie ganz klein sind [1].

Die letzten Jahre sind von einer sehr regen Forschungsaktivität im Bereich der Anwendung von neuronalen Netzen zur Detektion und Klassifikation von Brustkrebs geprägt. Mehrschichtige Perzeptrons sind z.B. in [2] zur Detektion und Klassifikation von Mikrokalzifikationen eingesetzt worden.

Die Wavelet-Transformation ist in CAD-Systemen hauptsächlich zum Bildenhancement und zur Detektion von Mikrokalzifikationen eingesetzt worden. Die Verwendung der Wavelet-Transformation bei der Detektion von Massen wurde erstmals von Wei et al. vorgestellt [3]. Laine et al. [4] haben zum ersten Mal die Anwendung der Wavelet-Transformation für die Merkmalsextraktion bei Mammographie-Aufnahmen gezeigt. So können überabgetastete Wavelet-Transformationen bei jeder Skala die örtliche Lokalisation der Masse dank der Translationsinvarianz erhalten.

## 2 Das neuronale Radialbasisnetz

Neuronale Netze mit Radialbasisklassifikatoren stellen einen universellen Approximator bei einem dreischichtigen Aufbau dar. Die Ein- und Ausgangsschicht bestehen aus linearen Einheiten. Die Neuronen der verborgenen Schicht bestimmen den euklidischen Abstand zwischen Eingangs- und Referenzvektor und bewerten diesen schließlich über eine Radialbasisfunktion, die meistens eine Exponentialfunktion ist. Die Ausgangsschicht realisiert die Überlagerung der gewichteten Radialbasisneurone der mittleren Schicht und damit die Approximation der geforderten Funktion.

## 3 Merkmalsextraktion

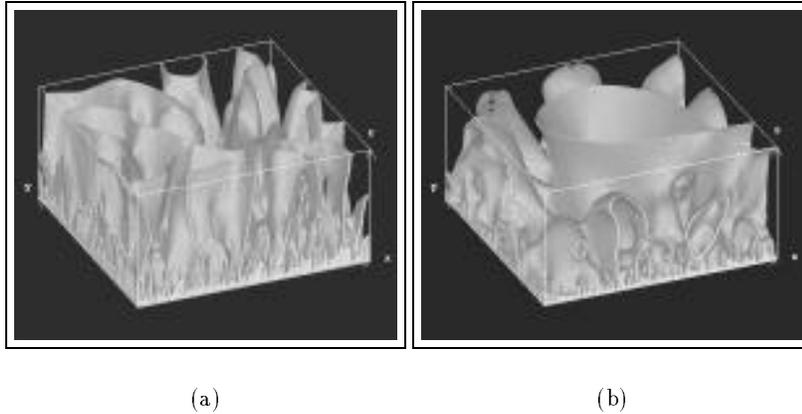
Das System zur Erkennung von Massen arbeitet mit den vier üblichen Standardaufnahmen pro Brustkrebsfall. Für jede einzelne Aufnahme wird eine überabgetastete Wavelet-Darstellung durchgeführt sowie eine Darstellung bei kontinuierlichen Skalen zum Zwecke der Multi-Resolution-Analyse. Diese Darstellungen sind nötig, um für jeden Bildpunkt Merkmale bei verschiedenen Skalen zu extrahieren. Die Wavelet-Koeffizienten bei verschiedenen Auflösungen für jeden einzelnen Pixel bilden einen Merkmalsvektor und werden damit zum Eingangsvektor eines neuronalen Netzes. Der Ausgang vom Netz entscheidet über die Wahrscheinlichkeit, ob ein Bildpunkt zu einem Bereich einer Masse gehört. Ein anschließendes Schwellwertverfahren erstellt eine binäre Maske, die die krebsverdächtigen Gebiete segmentiert.

## 4 Netzaufbau, Segmentierung und Klassifikationsergebnisse

Die Aufgabe des neuronalen Netzes ist es, eine binäre Maske zu erzeugen, die die Segmentierung der Massen in der Mammographie-Aufnahme ermöglicht.

In diesem Sinne wird ein Fenster der festen Größe von  $256 \times 256$  Pixeln über 18 Volumenaufnahmen der Transformationskoeffizienten des Bildes gestreift. Die Überlappungsrate beträgt dabei 50%. Bei jedem Überlappungspunkt werden die 3-D Skalenmerkmale extrahiert und dem neuronalen Netz als Eingangsvektor angeboten. Die Länge des Eingangsvektors ist somit durch die vorgegebene Anzahl der Merkmale gegeben. Der Ausgang des Netzes entscheidet über die Zugehörigkeit eines Pixels zu einer Masse. Die Neuronen der mittleren Schicht entstehen während des Lernvorganges und sollen die Umrisse der Massen lernen. Das neuronale Radialbasisnetzwerk ist optimal zum Lernen von Skalierungsraum-Darstellungen, da die Kernelfunktionen Hyperellipsoide darstellen können. Die durchgeführten Voruntersuchungen haben gezeigt, daß die Koeffizienten bei der kontinuierlichen Wavelet-Analyse Strukturformen (Cluster) annehmen, die durch die Überlagerung von Hyperellipsoiden gut nachgebildet werden können.

Ein Vergleich zwischen der Visualisierung von Bildern, die normales Brustgewebe und solche mit Verschattungen mit radiären Ausziehungen enthalten (Bild 1(a) und (b)), zeigt, daß diese Strukturen mit Hilfe von Linearkombinationen hyperellipsoidischer Cluster im Raum approximiert werden können. Diese Strukturen können besonders gut mittels neuronaler Radialbasisnetzwerke erkannt werden, da die 3-D rezeptiven Felder diese Formen optimal nachbilden können. Die uns zur Verfügung stehende Datenbank enthält 310 unterschiedliche Fälle mit je 4 Mammographie-Aufnahmen pro Fall, und es wurden die Hälfte zum Training und die andere Hälfte zum Testen genommen.



**Abbildung 1.** 3D-Visualisierung der Nulldurchgänge von kontinuierlichen Waveletkoeffizienten eines Bereiches (a) ohne Masse und (b) mit Masse (9mm).

Die Erkennungsrate des neuronalen Netzes bei der Massensegmentierung liegt bei 92,2%.

## 5 Globale und lokale Kontrastverstärkung

Die Bilder 2 und 3 beschreiben die verschiedenen Verarbeitungsschritte, die für die globale und lokale Kontrastverstärkung benötigt werden. Ausgangspunkt des Verfahrens ist - wie üblich - eine digitalisierte Mammographie-Aufnahme.

**Globale Kontrastverstärkung:** Eine Kontrastverstärkung wird für jeden Bildpunkt in einem gerade durchgestreiften Bereich eines Bildes oder sogar über das gesamte Bild durchgeführt. Das Problem bei der globalen Kontrastverstärkung ist, daß es zwar sehr geeignete Merkmale findet, jedoch Bilder erzeugt, die für den Radiologen ohne zusätzliche Interpretationshilfen wenig brauchbar sind. Um jedoch auf die Vorteile dieses Verfahrens nicht verzichten zu müssen, wird eine Bildfusion vorgenommen, die die lokal und global kontrastverstärkten Bilder miteinander verknüpft.

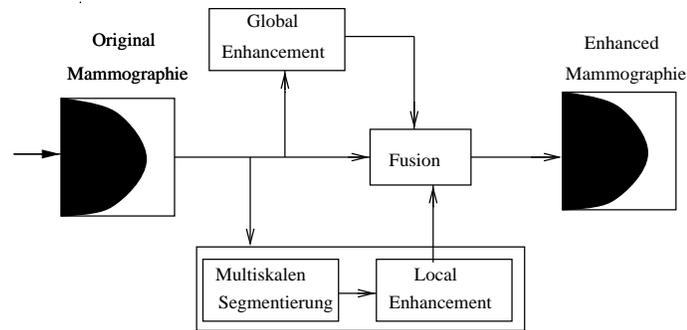


Abbildung2. Multi-Skalen Kontrastverstärkung.

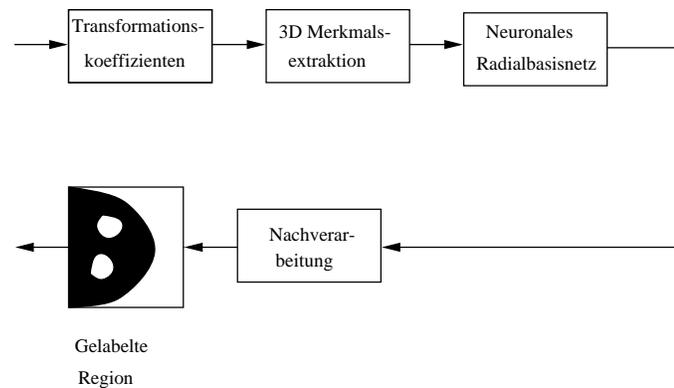


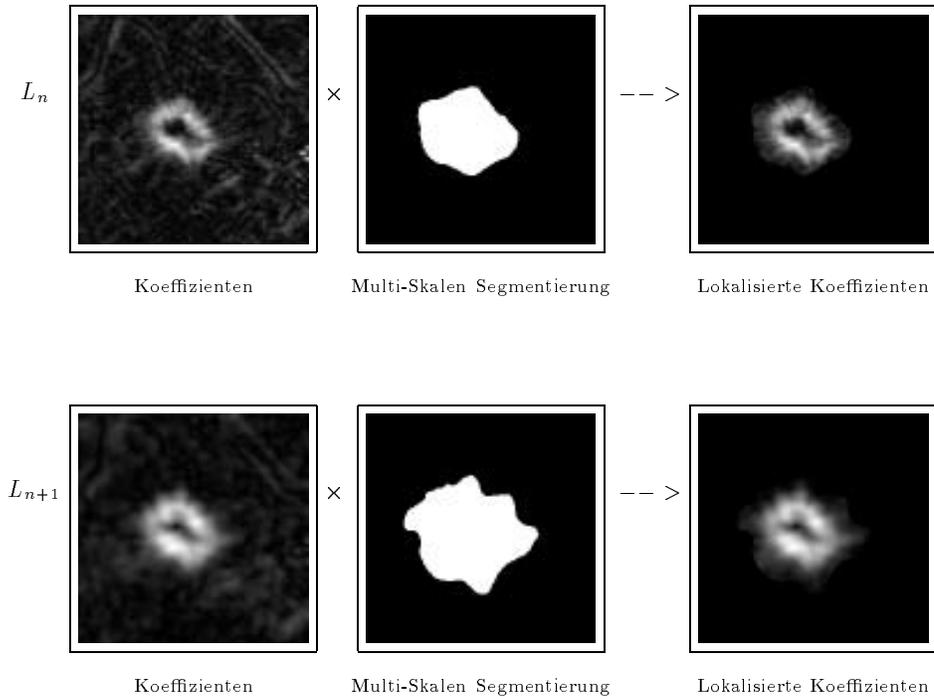
Abbildung3. Verarbeitungsstufen der Multi-Skalen Segmentierung von Massen.

**Lokale Kontrastverstärkung:** In [4] ist gezeigt worden, daß lokale Kontrastverstärkungsverfahren, die gezielt auf krebserdächtige Gebiete fokussiert sind, größere Vorteile als globale Verfahren haben. Nachdem die Segmentierung anhand des neuronalen Netzes durchgeführt wurde, kann die lokale Kontrastverstärkung vorgenommen werden.

Eine anschließende Fusion einer globalen Kontrastverstärkung des gesamten Bildes sowie einer lokalen Kontrastverstärkung der segmentierten Region unterstützen den Radiologen bei seiner Diagnose. Bild 4 enthält eine Auswahl von lokalisierten Transformationskoeffizienten.

## References

1. Tabar R, Dean P: Teaching Atlas of Mammography. Thieme Inc., New York,



**Abbildung4.** Lokalisierte Waveletkoeffizienten anhand einer Glättungsfunktion bei einer Approximation einer Ableitung 1. Ordnung bei zwei verschiedenen Analysestufen; Obere Reihe: Feinere Skala, Untere Reihe: Grobere Skala.

1985.

2. Zhang W, Wu Y, Giger M, Doi K, Nishikawa R: Computerized Detection of Clustered Microcalcifications in Digital Mammograms Using a Shift-Invariant Neural Network. *Med. Phys.*, 21:517-524, 1994.
3. Wei D, Chan H, Helvie M, Sahiner B: Classification of Mass and Normal Breast Tissue on Digital Mammograms: Multiresolution Texture Analysis. *Med. Phys.*, 22:1501-1513, 1995.
4. Laine A, Schuler S, Fan J, Huda W: Mammographic feature enhancement by multiscale analysis *IEEE Trans. on Medical Imaging*, 13:725-740, 1994.