

DOKU TİPİ İMGELERİN SINIFLANDIRILMASI İÇİN BİR UYARLAMALI ENTROPİ TABANLI DALGACIK-YAPAY SİNİR AĞI SİSTEMİ

Engin AVCI

Elektronik ve Bilgisayar Eğitimi Böl., Teknik Eğitim Fak., Fırat Üniv., 23119 Elazığ, enginavci@firat.edu.tr

(Geliş/Received:07.11.05; Kabul/Accepted:18.04.06)

ÖZET

Günümüzde, doku tipi imgelerin analiz ve sınıflandırılması konusu önemli bir hal almıştır. Doku tipindeki imgelerin sınıflandırılmasında geçmişte karşılaşılan en büyük güçlük, bu tür imgelerin doğru karakterize edilebilmesi için yeterli yöntemlerin geliştirilememesidir. Ancak son zamanlarda, Gabor süzgeçleri, dalgacık ayrışmaları gibi çok çözünürlüklü analiz yöntemlerinin doku tipi imgelerin sınıflandırılmasında diğer klasik yöntemlere göre üstün başarı sağladıkları görülmektedir. Bu çalışmada ise, Brodatz imge albümünden elde edilen 20 adet doku tipi resmin sınıflandırılabilmesi için, uyarlamalı norm entropi tabanlı bir dalgacık-yapay sinir ağı yapısı geliştirilmiştir. Kullanılan yapay sinir ağı çok katmanlı geriye yayımlı yapıya sahiptir. Yapılan test çalışmalarında geliştirilen yöntemin etkinliği denenmiş ve ortalama % 90 oranında bir tanıma başarısı elde edilmiştir.

Anahtar kelimeler: Doku tipi imgeler, akıllı sınıflandırma, dalgacık dönüşümü, entropi, yapay sinir ağları.

A WAVELET – ARTIFICIAL NEURAL NETWORK SYSTEM BASED ON ADAPTIVE ENTROPY FOR TEXTURE IMAGES CLASSIFICATION

ABSTRACT

Nowadays, analysis and classification of texture images analysis and classification becomes an important topic. In the past, greatest difficulty in classification of texture images was the deficiency of enough methods to characterize. Recently, it is seen that, multi-resolution analysis methods such as Gabor filters, wavelet decompositions are superior to other classic methods. In this study, a wavelet-artificial neural network structure based on adaptive norm entropy was developed for classification of the 20 texture images obtained from Brodatz image album. The artificial neural network used in this study has a multi layer, back propagation structure. Efficiency of the developed method was tested showing that an average of %90 recognition success was obtained.

Keywords: Texture images, intelligent classification, wavelet transform, entropy, artificial neural networks.

1. GİRİŞ (INTRODUCTION)

Doku tipi yani içerik tabanlı imgelerden dayanıklı özellikler çıkarmak, günümüzde çok önemli bir konu haline gelmiştir [1]. Doku tipi imgeler düşük seviye imge özelliklerine sahiptir. Günümüzde, tıbbi görüntüleme, endüstriyel araştırmalar, doküman bölütleme ve sınıflandırma, radar imgelerinin tanınması ve sınıflandırılması ve doku tipi imgelerin orijinallerinin yeniden elde edilmesi gibi birçok alanda doku tipi imgelerin analizi kullanılmaktadır [2]. Doku tipi imgelerin analizi için çeşitli yöntemler geliştirilmiştir. İstatistiksel yöntemler bunlardan biridir. Bu yöntemde doku tipi imgelerin istatistiksel analizi için genelde bu tip imgeler düz,

pürüzlü vb. sınıflara ayrılır [3]. Bir başka analiz türü de Gaussian Markov Rasgele Alanları (GMRA) gibi olasılıksal modeller ve otoregrasyon yöntemleri kullanılmaktadır [4]. Bu alandaki en son gelişmelerle artık son zamanlarda doku tipi imgelerin analizi Gabor süzgeçleri [5-6] ve dalgacık ayrışmaları gibi çok çözünürlüklü zaman-frekans yöntemlerine kaymıştır [7-9]. Bu tip yöntemler, doku tipi imgelerin analiz ve sınıflandırılması için çok iyi çözünürlüklü analitik araçlar sağlamaktadır [10].

Doku tipi imgeleri tam olarak analiz etmek, sınıflandırmak ve tanınmasını sağlamak için bu imgelerden çıkarılacak ayırt edici özelliklerin yeterli olması gere-

kir. Günümüze kadar doku tipi imgelerin analizi için kullanılan eski özellik çıkarım yöntemlerinin kullanıldığı çalışmaları aşağıdaki gibi sınıflandırabiliriz:

- Doku tipi imgelerin birinci ve ikinci dereceden istatistiksel özellikleri kullanılarak yapılan çalışmalar [10-14].
- Gaussian Markov Rasgele Alanlar (GMRA) ve Gibbs Rasgele Alanlar (GRA)'nın kullanıldığı çalışmalar [15-20].
- Yerel doğrusal dönüşümlerin önerildiği çalışmalar [21, 22].
- Co-occurrence matris özelliklerinin kullanıldığı çalışmalar [10].

Doku tipi imgelerin farklı bölgelerinin aynı karakteristik özellikleri göstermesi gerekmesine rağmen yukarıda maddeler halinde verilen yöntemlerin birçoğunun bunu sağlayamaması bu klasik yöntemlerin en büyük dezavantajlarıdır. Örneğin 512×512'lik bir doku tipi imgede birbiriyle örtüşen ya da örtüşmeyen (overlapping ya da non-overlapping) rasgele seçilmiş her 128×128'lik veya 64×64'lük piksel bölgelerinin (imge parçalarının) birbiriyle aynı veya hemen hemen birbirine yakın karakteristik özellikler göstermesi gerekmektedir. Ancak yukarıda verilen klasik yöntemlerle yapılan doku analizlerinde karşılaşılan en büyük sorun bir imge üzerindeki rasgele seçilmiş aynı boyutlu imge bölgelerinin (parçalarının) her birinden aynı ya da birbirine benzer karakteristik özelliklerin elde edilemeyeşidir. Bundan dolayı bu makalede doku tipi imge analizinde en popüler yöntemlerden biri haline gelen dalgacık dönüşüm yöntemi kullanılmıştır; çünkü dalgacık dönüşümü, bir resmin rasgele seçilmiş aynı boyutlu farklı bölgeler arasındaki karakteristik farkını en aza indirgeyebilen dayanıklı özellikler ortaya koyarak, bu piksel gruplarının aynı resmin parçaları olduğunu ifade etmekte kolaylıklar sunmaktadır [9]. Bundan başka dalgacık dönüşümü, getirmiş olduğu çoklu çözünürlük özelliği ile farklı ölçütlerdeki imgelerin dayanıklı tanıma performanslarını artırmaktadır. Bundaki en büyük etkenlerden bir olarak da dalgacık dönüşümünde kullanılan düşük ve yüksek bant süzgeçlerinin, bir resmin farklı ardışık ölçeklerdeki parçaları için aynı kalabilmesidir [9].

Bu çalışmanın yapılmasındaki ana amaçlar şu şekilde özetlenebilir:

- Ayrık Dalgacık Dönüşüm (ADD) yönteminin uyarlamalı norm entropi özelliği ile birleşiminin doku tipi imgelerin analizindeki performansını göstermek.
- Doku tipi imgelerin analizinde, Uyarlamalı Norm Entropi tabanlı Dalgacık Yapay Sinir Ağı (UNE-DYSA) algoritması kullanarak, bir resmin rasgele seçilmiş aynı boyutlu birbirinden farklı bölgelerinin her birinin aynı imge olarak tanınmasını sağlamak.

Bu çalışmada yapılan deneysel uygulamalarda Brodatz albümünden [23] elde edilmiş her biri 512×512 ebadında toplam 20 adet doku tipi imge kullanılmıştır. Bu

imgelerin her biri ilk önce birbirleriyle örtüşen ya da örtüşmeyen 40 adet 128×128'lik rasgele imge bölgelerine ayrılmıştır. Her bir imge için elde edilen 128×128'lik bu imge bölgelerinin 15 adedi UNE-DYSA algoritmasının eğitiminde, geri kalan 25 adedi ise bu algoritmanın doğru sınıflandırma başarımını test etmede kullanılmıştır. Bu amaç için öncelikle 20 adet resmin her biri için elde edilen bu 128×128'lik rasgele imge bölgelerinin her birinin 1. seviyeye göre Ayrık Dalgacık Dönüşümleri (ADD) alınmıştır. 1. seviyeye göre her bir 128×128'lik resmin bir yaklaşık ve üç adet de detay katsayısı ADD ile bulunmuştur. Bu bulunan yaklaşık ve detay katsayılarının her biri için ayrı ayrı uyarlamalı norm entropi ve Shannon entropi değerleri hesaplanmıştır. Her bir 128×128'lik imge için elde edilen bu 4 adet uyarlamalı norm entropi ve 4 adette Shannon entropi değerleri eğitim için UNE-DYSA algoritmasına verilmiştir.

Bu makale şu şekilde özetlenebilir: Bölüm 2'de ADD ve DYSA hakkında genel bilgiler verilmiştir. Bölüm 3'te bu çalışmada kullanılan özellik çıkarımı ve sınıflandırma yöntemi açıklanmıştır. Bölüm 4'te doku tipi imgelerin sınıflandırma deneysel çalışma sonuçları verilmiştir. Bölüm 5'te ise elde edilen sonuçlar irdelenmiştir.

2. TEMEL BİLGİLER (BASIC INFORMATION)

2.1. Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)

Dalgacık dönüşümü, son zamanlarda radar hedef tanıma, haberleşme, doku imge sınıflandırma gibi birçok farklı alanda özellik çıkarımı, işaret ve imgelerin çok çözünürlüklü analizi için yaygın kullanılan bir yöntem haline gelmiştir [24]. Dalgacık dönüşümlerinin en büyük avantajı bu dönüşümlerin değişken pencereleme boyutuna sahip olmasıdır ki, bu pencereleme boyutu, düşük frekanslar için geniş ve yüksek frekanslar için dardır. Böylelikle bu durum bütün frekans aralıklarında bir optimum zaman-frekans çözünürlüğü sağlamaktadır [25, 26].

Bu çalışmada doku tipi imgelerin dalgacık dönüşümleri alınırken, imge ADD uygulanarak 4 alt banda ayrılır. Bu alt bantlar Şekil 1'de gösterilmiştir. Bu alt bantlar A-Y (Alçak geçiren süzgeç-Yüksek geçiren süzgeç), Y-A (Yüksek geçiren süzgeç- Alçak geçiren süzgeç), Y-Y (Yüksek geçiren süzgeç-Yüksek geçiren süzgeç) olmak üzere üç detay katsayısından ve A-A (Alçak geçiren süzgeç-Alçak geçiren süzgeç) olmak üzere 1 adet yaklaşık katsayısından oluşmaktadır.

Ayrışım Seviyesi = 1

A-A	Y-A
A-Y	Y-Y

Şekil 1. 1 seviyeli imge ayrışımı ve ADD'nin alt bantları (1-level image decomposition and subbands of the DWT)

2.2. Dalgacık Yapay Sinir Ağları (Wavelet Artificial Neural Networks)

Yapay Sinir Ağları (YSA), insan beyin yapısının taklit edilmesi ile ortaya çıkmış ve öğrenmeye dayalı sistemlerdir [27]. Bu sistemler, bilgi işleme sistemlerinin günümüzdeki jenerasyonlarını temsil etmektedir. Yapay sinir ağları, günümüzde sınıflandırma, fonksiyon yaklaşırma, optimizasyon ve veri kümeleme gibi birçok farklı alanlarda kullanılmaktadır [28].

Dalgacık Yapay sinir Ağları (DYSA) ise dalgacık dönüşümü ile yapay sinir ağlarının bir kombinasyonundan oluşmaktadır. Bu yapıda dalgacık dönüşümü, özellik çıkarımı için kullanılırken, yapay sinir ağları ise çıkarılan bu özellikleri sınıflandırmada kullanılır [25]. Dalgacık dönüşümü, durağan olmayan işaret analizi için güçlü bir araçtır [25]. $x(t)$ burada parçalı sürekli bir fonksiyon olsun. Dalgacık ayrışımı, bir $\psi : R^n \rightarrow R$ şeklinde dalgacık fonksiyonu kullanarak, $x(t)$ fonksiyonunu ayrıştırmaya izin verir. Dalgacık ayrışım tabanlı olarak, DYSA yapısı aşağıdaki gibi tanımlanabilir:

$$y(x) = \sum_{i=1}^N w_i \psi[D_i(x - t_i)] + b \quad (1)$$

Burada D_i skala matrisidir, t_i dönüşüm vektörüdür, b ise bias'tır. Bu çalışmada, DYSA'nın parametrelerinin ayarlanması için geriye yayılım algoritması kullanılmıştır. DYSA uygulamaları tıpta kroner arter hastalıklarının sınıflandırılması [24-27], kalp kapakçıklarının karakterize edilmesi [24], EKG işaretlerinin sınıflandırılması [24] ve radar hedeflerinin otomatik tanınması [24] gibi birçok alanda kullanılmıştır. Ancak bu yöntem


uyarlamalı norm entropi tabanlı olarak ilk defa bu çalışmada doku tipi imgelerin sınıflandırılması uygulamasında kullanılmıştır. Yani bu alanda henüz yeni bir uygulamadır.

3. UYGULANAN ÖZELLİK ÇIKARIM VE SINIFLANDIRMA YÖNTEMİ (THE APPLIED FEATURE EXTRACTION AND CLASSIFICATION METHOD)

Bu çalışmada yapılan deneysel uygulamalarda kullanılan Brodatz albümünden [23] elde edilmiş 20 adet doku tipi imge sıra ile Şekil 2'de verilmiştir.

Bu çalışmada kullanılan özellik çıkarım ve sınıflandırma yöntemleri iki aşamada ele alınabilir:

Aşama-1 (Stage-1): Bu aşama özellik çıkarım safhasıdır. Burada Brodatz albümünden elde edilmiş toplam 20 adet 512×512 'lik doku tipi imge kullanılmıştır. Şekil 2'de bu imgeler verilmiştir. Bu imgelerin her biri için birbiriyle örtüşen ya da örtüşmeyen (overlapping ya da non-overlapping) rasgele seçilmiş 40 adet 128×128 'lik imge bölgesi elde edilmiştir. Her bir imge için elde edilen bu 128×128 'lik imge bölgelerinin 15 adedi UNE-DYSA algoritmasının eğitiminde, geri kalan 25 adedi ise bu algoritmanın test aşamasında kullanılmıştır. Bunun için ilk önce 20 adet resmin her biri için elde edilen bu 128×128 'lik rasgele imge parçalarının her birinin 1. seviyeye göre Ayrık Dalgacık Dönüşümleri (ADD) alınmıştır. 1. seviyeye göre her bir 128×128 'lik resmin bir yaklaşık ve üç adet de detay katsayısı ADD ile bulunmuştur. Bu bulunan yaklaşık ve detay katsayılarının her biri için Denklem 2 ve Denklem 3'te verilen uyarlamalı norm entropi ve Shannon entropi değerleri ayrı ayrı hesaplanmıştır.



Şekil 2. Brodatz doku tipi imge albümü. Soldan sağa ve yukarıdan aşağıya: D1, D4, D5, D6, D9, D11, D16, D17, D18, D20, D21, D26, D29, D32, D34, D47, D57, D64, D65, D77 (Brodatz texture images. From left to right and top to bottom: D1, D4, D5, D6, D9, D11, D16, D17, D18, D20, D21, D26, D29, D32, D34, D47, D57, D64, D65, D77)

$$\text{Norm entropi} = \frac{\sum_{i,j=1}^K |d(i,j)|^p}{K} \quad (2)$$

Burada $d(i,j)$ iki boyutlu bir imge, i,j ise resmin her bir pikselidir. p güç terimidir ve $1 \leq p < 2$ olmalıdır.

$$\text{Shannon entropi} = - \sum_{i,j=1}^K d(i,j) \log_2 d(i,j) \quad (3)$$

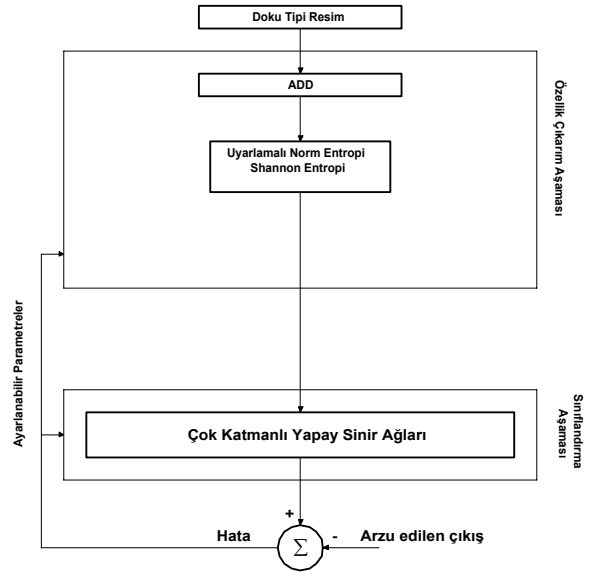
Her bir 128×128 'lik imge için elde edilen bu 4 adet uyarlamalı norm entropi ve 4 adet de Shannon entropi değerleri olmak üzere toplam $15 \times 20 \times 8 = 300 \times 8$ 'lik özellik vektörü eğitim için UNE-DYSA algoritmasına verilmiştir. Geriye kalan $25 \times 20 \times 8 = 500 \times 8$ 'lik özellik vektörü ise bu algoritmanın doğru sınıflandırma performansını değerlendirmek için test aşamasında kullanılmıştır.

Aşama-2 (Stage-2): Bu aşama sınıflandırma safhasıdır. Burada, özellik çıkarım safhasında elde edilen 300×8 'lik özellik vektörü kullanılarak yapay sinir ağları ile akıllı bir sınıflandırma yapılmıştır. Kullanılan çok katmanlı algılayıcı yapılı yapay sinir ağının eğitim parametreleri ve yapısı Tablo 1'de gösterilmektedir. Bu değerler, örneğin gizli katman sayısı, gizli katmanlardaki hücre sayısı, öğrenme oranı ve moment sabitinin değeri ve aktivasyon fonksiyonu, birkaç farklı denemeden sonra en iyi performansı verebilecek şekilde seçilmiştir. UNE-DYSA algoritmasının eğitimi süresince norm entropinin p parametresi (her bir alt bant için hesaplanan norm entropinin p parametresi), hatayı minimize edebilmek amacıyla DYSA ağırlıkları ile birlikte 0,1'lik değer artırım adımları kullanılarak, uyarlanır. Uyarlamalı norm entropi kavramı buradan ortaya çıkar. Elde edilen sonuç entropi değerleri en büyük entropi değerine bölünerek, normalize edilir. Bu çalışmada doku tipi imgelerin sınıflandırılması için kullanılan UNE-DYSA algoritmasının yapısı Şekil 3'te verilmiştir.

Aşama-3 (Stage-3): Bu aşama ise 2. aşamada UNE-DYSA algoritması kullanılarak gerçekleştirilen sınıflandırma sonuçlarının doğruluğunu test etmektedir. Bu amaçla daha önceden belirtildiği gibi her bir 512×512 'lik resmin 40 adet rasgele seçilmiş 128×128 'lik parçalarının geriye kalan 25 adedi kullanarak, $25 \times 20 \times 8 = 500 \times 8$ 'lik özellik vektörü elde edilmiştir. Daha sonra bu 500×8 'lik

Tablo 1. Çok katmanlı yapay sinir ağının yapısı ve eğitim parametreleri (Structure and training parameters of multi-layer artificial neural network)

Katman sayısı	3
Katman hücre sayıları	Giriş: 8, Gizli Katman: 15, Çıkış: 20
Başlangıç ağırlıkları ve biasları	The Nguyen-Widrow yöntemi
Aktivasyon fonksiyonları	Log-sigmoid
Eğitim parametreleri Öğrenme kuralı	Geriye yayılım
Uyarlamalı öğrenme oranı	Başlangıç: 0.0001 Artırım: 1.05 Azaltım: 0.7
Moment sabiti	0.98
Toplam karesel hata	0.00001



Şekil 3. Doku tipi imgelerin sınıflandırılması için kullanılan UNE-DYSA algoritmasının yapısı (Structure of ANE-WANN algorithm used for classification of texture images)

özellik vektörü UNE-DYSA algoritmasının doğru sınıflandırma performansını değerlendirmek için test aşamasında kullanılmıştır.

4. DENEYSEL SONUÇLAR VE TARTIŞMA (EXPERIMENTAL RESULTS AND DISCUSSION)

Bu çalışmada yapılan deneysel uygulamalarda her biri 512×512 'lik 20 adet Brodatz doku tipi imge kullanılmıştır. 3. Bölüm'de anlatıldığı gibi bu imgelerin her birinden 40 adet rasgele 128×128 'lik imge bölgeleri elde edilmiş ve bu imge parçalarının 15 adedi UNE-DYSA algoritması ile sınıflandırma, geriye kalan 25 adedi ise bu algoritmanın sınıflandırma başarımını test etmek için kullanılmıştır. UNE-DYSA algoritması kullanılarak elde edilen bu 20 resmin sınıflandırılması başarımları Tablo 2'de verilmiştir.

5. SONUÇLAR (RESULTS)

Bu çalışmada, UNE-DYSA algoritması tabanlı bir akıllı doku tipi imge sınıflandırma sistemi geliştirilmiştir. Bu sistemin sınıflandırma başarımı her bir imge için birbirinden farklı 25 adet rasgele seçilmiş 128×128 ebatlarında imge bölgeleri kullanılarak test edilmiştir. Bu sistemin doğru sınıflandırma performansı Tablo 2'de verilmiştir. Buradan da görüldüğü gibi uyarlamalı özellik çıkarımı ve sınıflandırma görevlerinin her ikisini bir arada yapabilme yeteneğine sahip olan UNE-DYSA algoritması % 90.8 gibi üstün bir tanıma performansı göstermiştir.

UNE-DYSA algoritmasının diğer algoritmalarla göre en büyük üstünlüklerinden biri de az sayıda özellik kullanarak üstün bir tanıma performansı göstermiş olmasıdır. Örüntü tanıma uygulamalarının temel bileşenlerinden biri özellik çıkarımıdır. Bir örüntüyü mümkün olan en iyi şekilde özetleyecek az sayıdaki özellikleri elde etmek, örüntü tanımanın temel prensibidir [24-27].

Tablo 2. UNE-DYSA algoritması kullanılarak yapılan sınıflandırma çalışmasının doğruluk performansı (Correctness performance of classification study realized by using ANE-WANN algorithm)

İmge Sıra No:	Doku Tipi İmge No:	Doğru Sınıflandırma Oranı (%)
1	D1	%96
2	D4	%92
3	D5	%92
4	D6	%84
5	D9	%84
6	D11	%96
7	D16	%92
8	D17	%88
9	D18	%96
10	D20	%88
11	D21	%84
12	D26	%96
13	D29	%88
14	D32	%84
15	D34	%96
16	D47	%96
17	D57	%96
18	D64	%100
19	D65	%96
20	D77	%84
Doğru Sınıflandırılmış İmge Bölgelerinin Sayısı		454
Kullanılan İmge Bölgelerinin Toplam Sayısı		500
Ortalama Başarı Oranı (%)		%90.8

UNE-DYSA algoritması, bu çalışmada kullanılan 20 adet doku tipi resmin her birinden rasgele elde edilen 128×128'lik bir birinden farklı imge bölgelerinin her birinden birbirine yakın tanımlayıcı özellikler çıkarmada da başarılı olmuştur. Bu ortak özelliklerin çıkarımında en etkili faktörler olarak, UNE-DYSA algoritma yapısında kullanılan dalgacık dönüşümü ve uyarlamalı norm entropi özellikleri göze çarpmaktadır. Ayrıca bu algoritmanın en önemli özelliklerinden biri de gerçek zaman uygulamalarında herhangi bir kullanıcı müdahalesi olmadan kendi kendini ayarlayabilmesidir.

Hızlı olması ve pahalı bir yapıya sahip olmaması UNE-DYSA algoritmasının diğer avantajlarından birkaçıdır. Bu sistem doku tipi imgelerin sınıflandırılmasında kullanıldığı gibi sonraki çalışmalarda ultrasonografik, mamografik ve endoskopik türden tıbbi görüntülerin sınıflandırılmasında da kullanılabilir.

SEMBOLLER (SYMBOLS)

$d(i,j)$: İki boyutlu bir imge
 i,j : Resmin her bir pikseli
 p : Güç terimi
 $x(t)$: Parçalı sürekli bir fonksiyon
 $\psi: R^n \rightarrow R$: Ayırışım fonksiyonu

KAYNAKLAR (REFERENCES)

- Pun, C. ve Lee, M., "Extraction of Shift Invariant Wavelet Features for Classification of Images with Different Sizes", **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Cilt:26, No.9, Eylül 2004.

- Tuceryan, M., ve Jain, A. K., **Texture Analysis, Handbook of Pattern Recognition and Computer Vision**, 235-276, World Scientific, 1993.
- Connors R.W., ve Harlow, C.A., "A Theoretical Comparison of Texture Algorithms," **IEEE Trans. Pattern Analysis and Machine Intelligence**, Cilt 2, 204-222, Mayıs 1980.
- Bovik, A., C., Clark, M., ve Geisler, W., S., "Multichannel Texture Analysis Using Localized Spatial Filters," **IEEE Trans. Pattern Analysis and Machine Intelligence**, Cilt No: 12, Ocak 1990.
- Teuner, A., Pichler, O., ve Hosticka, B., J., "Un-supervised Texture Segmentation of Images Using Tuned Matched Gabor Filters," **IEEE Trans. Image Processing**, Cilt:6, No:4, 863-870, 1995.
- Chang, T., ve Kuo, C.C.J., "Texture Analysis and Classification with Tree-Structured Wavelet Transform", **IEEE Trans. Image Processing**, Cilt: 2, 429-441, Nisan 1993.
- Laine, A., ve Fan, J., "Texture Classification by Wavelet Packet Signatures", **IEEE Trans. Pattern Analysis and Machine Intelligence**, Cilt:15, No: 11, 1186-1191, Kasım 1993.
- Unser, M., "Texture Classification and Segmentation Using Wavelet Frames", **IEEE Trans. Image Processing**, Cilt No: 4, 1549-1560, Kasım 1995.
- Pun, C., ve Lee, M., "Log-Polar Wavelet Energy Signatures for Rotation and Scale Invariant Texture Classification", **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Cilt:25, No:5, Mayıs 2003.
- Haralick, R. M., Shanmugam, K., ve Dinstein, I., "Texture Features for Image Classification", **IEEE Trans. System Man Cybernat.**, 8 (6), 610-621, 1973.
- Weszka, J. S., Dyer, C. R., ve Rosenfeld, A., "A Comparative Study of Texture Measures for Terrain Classification", **IEEE Trans. System Man Cybernat. SMC-6**, (4), 269-286, 1976.
- Davis, L. S., Johns, S. A., ve Aggarwal, J. K., "Texture Analysis Using Generalized Co-Occurrence Matrices", **IEEE Trans. Pattern Anal. Machine Intell. PAMI-1**, 251-259, 1979.
- Faugeras, O. D., ve Pratt, W. K., "Decorrelation Methods of Texture Feature Extraction", **IEEE Trans. Pattern Anal. Machine Intell. PAMI-1**, 323-332, 1980.
- Chen, P., C., ve Pavlidis, T., "Segmentation by Texture Using Correlation", **IEEE Trans. Pattern Anal. Machine Intell. PAMI-5**, 64-69, 1983.
- Cross, G., R., ve Jain, A., K., "Markov Random Field Texture Models", **IEEE Trans. Pattern Anal. Machine Intell. PAMI-5**, (1), 25-39, 1983.
- Kashyap, R. L., ve Khotanized, A., "A Model Based Method for Rotation Invariant Texture Classification", **IEEE Trans. Pattern Anal. Machine Intell. PAMI-8**, (4), 472-481, 1986.
- Chellappa, R., ve Chatterjee, S., "Classification of textures using Gaussian Markov Random Fields", **IEEE Trans. Acoustics Speech Signal Process. ASSP-33**, (4), 959-963, 1986.

18. Derin, H., ve Elliot, H., "Modeling and Segmentation of Noisy and Textured Images Using Gibbs Random Fields", **IEEE Trans. Pattern Anal. Machine Intell. PAMI-9**, 39–59, 1987.
19. Cohen, F., S., Fan, Z., ve Patel, M., A., "Classification of Rotation and Scaled Textured Images Using Gaussian Markov Random Field Models", **IEEE Trans. Pattern Anal. Machine Intell.**, 13 (2), 192–202, 1991.
20. Manjunath, B., S., ve Chellappa, R., "Unsupervised Texture Segmentation Using Markov Random Fields", **IEEE Trans. Pattern Anal. Machine Intell.**, 13, 478–482, 1991.
21. Laws, K. L., "Rapid Texture Identification", **Proc. SPIE**, 238, 376–380, 1980.
22. Unser, M., "Local Linear Transforms for Texture Measurements", **Signal Process.**, 11, 61–79, 1986.
23. <http://www.ux.his.no/~tranden/brodatz.html>, 2005.
24. Avcı, E., ve Turkoglu, I., "Modelling of Tunnel Diode by Adaptive-Network-Based Fuzzy Inference System", **Int. J. of Computational Intelligence**, Cilt:1, No:1, 231-233, Temmuz, 2003.
25. Avcı, E., Turkoglu, I., ve Poyraz, M., "Intelligent Target Recognition Based on Wavelet Packet Neural Network", **Experts Systems with Applications**, 29(1), 2005.
26. Avcı, E., Turkoglu, I., ve Poyraz, M., "A New Approach Based on Scalogram for Automatic Target Recognition with X-Band Doppler Radar", **Asian Journal of Information Technology**, Cilt: 4(1), 133-140, Ocak, 2005.
27. Avcı, E., Turkoglu, I., ve Poyraz, M., "Intelligent Target Recognition Based on Wavelet Adaptive Network Based Fuzzy Inference System", **Lecture Notes in Computer Science**, Springer-Verlag, Cilt: 3522 / 2005, 594-601, Mayıs, 2005.
28. Turkoglu, I., Arslan, A., ve Ilkay, E., "An Intelligent System for Diagnosis of the Heart Valve Diseases with Wavelet Packet Neaural Networks", **Computer in Biology and Medicine** 33, 319-331, 2003.