

## Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Döndürmeye Duyarsız Doku Analizi ve Sınıflandırma

**Abdulsamet HAŞİLOĞLU**  
*Atatürk Üniversitesi, Mühendislik Fakültesi,  
Elektronik ve Haberleşme Mühendisliği Bölümü,  
25240, Erzurum - TÜRKİYE*

Geliş Tarihi 08.06.1999

### Özet

Doku sınıflandırma amacı ile, çok sayıda doku analizi yaklaşımları önerilmiştir. Son olarak, Dalgacık çerçeveler, doku öznelik ayrışımı için teklif edildi. Bu çalışmada, alt-örnekleme dalgacık çerçeve dönüşümü, Brodatz albümünden alınan 16 adet doku örneğinin çeşitli dalgacık aileleri vasıtasıyla özneliklerinin saptanmasında kullanıldı. Doku sınıflandırma, hızlı adaptif geriye yayımlı algoritmali yapay sinir ağları kullanılarak gerçekleştirildi. Yapay sinir ağları sınıflandırıcısını eğitmek maksadı ile, rastgele döndürülmüş ve değişken boyutlarda doku pencereleri oluşturan yeni bir piramit pencereleme algoritması sunuldu ve tam bir sınıflandırma sonuçları elde edildi.

**Anahtar Sözcükler:** Doku, Dalgacık dönüşümü, Yapay sinir ağları, Sınıflandırma

## Rotation-Invariant Texture Analysis and Classification by Artificial Neural Networks and Wavelet Transform

### Abstract

A large number of approaches for texture analysis have been suggested for the purpose of texture classification. Recently, wavelet frames were proposed for texture features extraction. In this study, non-subsampled wavelet frame transform was used for feature extraction of 16 textures from a set of Brodatz' album by means of various wavelet families. Texture classification was accomplished by artificial neural network with a fast adaptive backpropagation algorithm. A new pyramidal-windowing algorithm is proposed, which forms randomly rotated texture windows of variable sizes texture windows for training a neural networks classifier, and perfect classification results were obtained.

**Key Words:** Texture, Wavelet transform, Artificial neural networks, Classification

### Giriş

Tanıma teknikleri, doku, görüntü, ses ve karakter tanıma başta olmak üzere pek çok alanda başarılı şekilde kullanılmaktadır (Pao, 1994). Bir dokuyu, genellikle, geometrik karakterde olsun olmasın, kısaca iyi tanımlanmış herhangi bir

ölçme dizisi olarak düşünmek olasıdır. Tanıma teknikleriyle örüntüye ait bir takım özneliklerin, (karakterize edilirken seçilen özellikler arasında) sınıflandırma performansını etkileyen sıkı bir ilişki söz konusudur (Çetiner, 1995). Doku, farklı örüntülerin ayırt edilmesinde önemli bir ipu-


çudur. Doku, görüntü bölgesinin gri seviyelerinin bölgesel komşuluk özelliklerinin bir kümesi olarak tanımlanabilir.

Doğada yer alan dokuların çoğu ve görüntü işlemedeki tüm dokular kararlı doku yerine yapısal veya istatistiksel temelli özellikler ile karakterize edilirler. Böylece doku, düzensiz veya düzenli olan ya da kaba veya ince olarak algılanabilir ve kararlı, yapısal ve düzensiz doku olarak üç ana kategori altında sınıflandırılabilir. Kararlı dokular, bazı matematiksel formüller ile tanımlanabilen temel yapı veya örüntülerin, iyi tanımlanmış yerleşim kurallarına göre bir araya geldiği dokulardır. Bu tür dokularda yapı taşları veya örüntülerin mükemmel şekilde tanımlanmasının yanı sıra yerleşim kuralları da çıkarılabilir. Yapısal dokular bazı yerleşim kurallarının veya dokuyu oluşturan örüntülerin sınırlı şekilde tanımlanabildiği dokulardır. Bir satranç tahtası görüntüsü örnek olarak verilebilir. Düzensiz (Stokastik) dokular kompleks resim yapıları olarak kabul edilir, düzensiz modellerle tanımlanır veya istatistiksel özellikler kümesiyle karakterize edilir. Bu dokularda yerleşim kuralları bulunmadığı gibi düzenli örüntülere de rastlanamaz.

Bu çalışmada Brodatz albümünden (Brodatz, 1966) 16 adet doku örneği seçildi. Doku öznitelik saptanması için alt-örnekleme (*non-sampled*) dalgacık çerçeve dönüşümü kullanıldı; tarafımdan geliştirilen yeni bir piramit pencereleme algoritması ile elde edilen alt-pencereleme dalgacık dönüşümünün uygulanmasıyla oluşan alt bantlara ait enerji değerleri doku öznitelikleri olarak seçildi. Doku sınıflandırıcısı olarak geriye yayımlı uyarlamalı algoritma yapay sinir ağları kullanıldı. Değişik dalgacık ailelerinin doku sınıflandırma performansının üzerindeki etkileri incelendi.

## Doku Sınıflandırma

Doku sınıflandırma, iki temel adımda özetlenebilir. Birinci adım, doku öznitelik saptanması, İkinci adım ise, saptanan doku öznitelikleri ile dokuların sınıflandırılmasıdır. Yapay sinir ağları ile sınıflandırma işlemi iki aşamada gerçekleşmektedir. Birinci aşama, sinir ağının eğitimi, yani, bağlantı ağırlıkların hesaplanmasıdır, ikinci aşama ise, eğitilmiş bir yapay sinir ağı ile dokuların sınıflandırılması olup, çoğunlukla gerçek-zamanlı uygulamalar şeklinde sanayide, tıpta ve benzeri dallarda karşımıza çıkmaktadır. Doku sınıflandırma *şekil-1* 'de şematik olarak gösterilmiştir.



Şekil 1. Doku sınıflandırma şeması

Başarılı bir doku sınıflandırma metodunun hızlı, yüksek tanıma başarısına sahip, öteleme ve döndürmeye karşı değişmez (*translation and rotation invariant*) olması istenir (Chen, 1994) yani kendisine tamamen raslantısal boyutlarda ve açılarda sunulan çeşitli doku örneklerini hızla ve hatasız bir şekilde tanıyabilmelidir. Bu açıdan, hem öznitelik saptanması hem de sınıflandırma metodunun yukarıda konu edilen performans kriterlerinin üzerinde etkin olacakları ortadadır. Son yıllarda klasik metodların yanısıra dalgacık dönüşümüne dayalı doku analizi oldukça rağbet kazanmıştır (Porter, 1996). Görüntülerin, insan beyninde çok skalalı bir şekilde algılanması çoklu çözünürlük tekniklerinin doku sınıflandırma alanında başarılı olabileceği kanaatini uyandırmıştır. Bu alanda geliştirilen metodlar içinde en yenisi dalgacık tabanlı yöntemlerdir (Unser, 1995).

## Dalgacık Dönüşümü

Görüntü dönüşümü, bir görüntünün yeni bir gösterimini sağlayan bir matematiksel işlem olup, dönüştürülmüş alanın taban fonksiyonları cinsinden, görüntünün frekans bileşenlerini ortaya çıkarır. Dalgacık dönüşümü, önceleri Fourier dönüşümünün kullanıldığı ve bazı açılardan yetersiz kaldığı veri analizi durumlarında, başarılı sonuçlar vermektedir (Akansu, 1995; Chan, 1996; Meyer, 1993; Strang, 1996) Örneğin değişimli küçük veya düzensiz ayrıntılara sahip işaretler ve görüntüler, geleneksel Fourier dönüşümüne oranla dalgacıklar ile genellikle daha iyi analiz edilirler (Meyer, 1993). Dalgacık dönüşümü, ses ve işitsel işaret işleme, görüntü ve video işaretleri işleme, haberleşme, jeofizik, ekonomi ve tıp gibi özellikle bir boyutlu ve iki boyutlu işaret işleme uygulamalarında yoğun olarak kullanılmaktadır.

Dalgacık dönüşümünün taban fonksiyonlarına "*dalgacık*" denir. Dalgacık, sınırlı süresi olan ve ortalaması sıfır olan bir dalga şeklindedir. Bir  $\psi(x)$  fonksiyonunun dalgacık adayı olabilmesi için,  $\psi(x)$  fonksiyonu sürekli olmalı ve  $x \rightarrow \infty$  için sıfır değerine git-

meli veya reel sayılar kümesinin bir parçası dışında sıfır değerine sahip olmalı. Bu parçaya dalgacığın desteği (*support*) denir.

Sıfır momentlere sahip olmalı, Dalgacığın ( $k + 1$ ) adet momentinin sıfır olması şartı

$$\int_{-\infty}^{+\infty} \chi^j \psi(x) dx = 0 \text{ ve } (j = 0, \dots, k) \quad (1)$$

şeklinde tanımlanır.

Dalgacık ile sayısal filtreler arasında yakın bir bağ mevcuttur. Dalgacık dönüşümünün iki temel parametresi vardır:

$a$  : dilasyon parametresi veya skala: Bir fonksiyonu (işaret, resim) sıkıştırır veya yayar.  $a$  'nın büyük değerleri küçük frekanslara (kaba skala),  $a$ 'nın küçük değerleri yüksek frekanslara (ince skala) karşılık gelir.

$b$  : öteleme parametresi ( shift), zaman (işaret) veya  $x, y$  boyunca (resim) dalgacığın ötelenmesini sağlar.  $a, b$  sürekli veya ayrık olabilir. Bu parametrelerin sürekli olması durumunda dalgacık fonksiyonu

$$\psi_{a,b}(t) = a^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

şeklinde ifade edilir. Ayrık olması durumunda, genellikle  $a = 2^j$  ve  $b = k2^j$  olarak tanımlanır. Böylece, dalgacık fonksiyonu ;

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j} t - k) \quad (3)$$

şeklinde ifade edilir. Dalgacık dönüşümü ile pencereleşmiş Fourier dönüşümleri arasındaki benzerlikler olmasına rağmen, bir kaç önemli farklılıklar da vardır (Daubechies, I., 1992).

### Doku Öznitelik Çıkarılması

Doku analizinde değişik öznitelikler kullanılmış, fakat hangisinin en uygun olduğu konusunda ortak bir sonuca varılamamıştır. (Laine and Fan, 1993) enerji ve entropi özniteliklerini karşılaştırmış ve enerji özniteliğinin daha uygun olduğu sonucuna varmışlardır. Enerji özniteliği, transformasyon ile elde edilen özniteliklerin toplamıdır. Dalgacık dönüşümünde, alt bantlara ait dalgacık kanal enerjisi, dalgacık katsayıların vasıtasıyla aşağıdaki basit bir formül (4) ile hesaplanır:

$$e = \frac{1}{p \cdot q} \sum_{i=1}^p \sum_{j=1}^q |x(i, j)| \quad (4)$$


Burada  $p, q$  kanal boyutları,  $x(i, j)$  dalgacık katsayılarıdır. Genellikle anizotropi bir çok

dokuda rastlanan özellik olup dokunun çevrilmesi ile tamamen farklı öznitelikler ortaya çıkarır. Sınıflandırma işleminde dokunun yönlendirilmesinden bağımsız sonuçların elde edilmesi arzu edilir bir durumdur.

Az sayıda öznitelik kullanılarak yapılan doku sınıflandırması, gerçek zamanlı uygulamalarda işlem hızı açısından önem arz etmektedir; Öznitelik sayısının çok olması daha çok bilgi taşımaya sağlanmasına karşılık öznitelik çıkarım zamanı da daha yüksek olur.

### Pencereleme Tekniği


Düzensiz dokuların özniteliklerinin, doku resminin değişik bölgelerinde oluşturulan belirli sayıda alt resimlerden (pencereler) çıkarılması, yapay sinir ağının doğru eğitilmesi için gereklidir. Bir doku örneğinden oluşturulan pencerelerden çıkarılan öznitelik vektörlerinin yarısı eğitim işleminde, diğer yarısı ise test işleminde kullanılmaktadır (Porter and Canagarajah, 1986). Düzensiz dokuların özniteliklerinin saptanmasında kullanılan pencereleme teknikleri örtüşmeyen (*non-overlapping*) veya örtüşen (*overlapping*) pencereleme teknikleridir. Örtüşmeyen pencereleme tekniğinde pencereler aynı boyutlarda yanyana birbirlerine çakışacak şekilde ve tüm resmi iki boyutta tarama olacak şekilde oluşturulmaktadır. Bu teknik *şekil-2*'de gösterilmiştir. Örtüşen pencereleme tekniğinde ise çoğunlukla aynı boyutta, birbirleriyle örtüşen ve doku resmini iki boyutta mümkün mertebe tarama bir alt pencereleme uygulanmaktadır. Bu teknik *şekil-3*'de gösterilmiştir.



Şekil 2. Örtüşmeyen (non-overlapping) pencereleme

Diğer yandan, bu doku pencereleri, genellikle orijinal doku döndürme işlemine tabi tutulmadan oluşturulmaktadır. Orijinal dokudan, döndürülmüş alt-pencereler oluşturularak yapay sinir ağının


eğitilmesinde kullanılması konusu üzerinde geçmiş çalışmalarda durulmadığı görülmüştür. Yaptığımız ön çalışmaların gösterdiği gibi, döndürmeden etkilenmeyen (rotation-invariant) doku sınıflandırma yöntemlerinin tanıma başarısı üzerinde pencereleme tekniği etkin olmaktadır.



Şekil 3. Örtüşen (overlapping) pencereleme

Literatürde uygulanan pencereleme yöntemleri döndürmeden etkilenmeyen doku sınıflandırma uygulamalarında yeterli bir performans elde edilemediğinden yeni pencereleme tekniklerin üzerinde durulmasının faydalı olacağı kanaatine varıldı. Bu maksatla iki ayrı pencereleme tekniği geliştirildi.


Diyagonal pencereleme tekniğinde, pencereler değişken boyutta, tüm dokuyu tarayacak şekilde, dokunun bir köşesi baz alınarak diğer köşeye doğru büyüyerek (veya küçülerek) oluşturulmaktadır. Bu teknik *şekil-4*'de gösterilmiştir.



Şekil 4. Diyagonal (köşeden köşeye) pencereleme

Piramit pencereleme tekniği ise, *şekil-5*'de gösterilmiştir. Bu teknikte doku resminin merkezine (diyagonallerin kesiştiği nokta) doğru sabit adımlarla giderek küçülen alt resimler oluşturulmaktadır. Her iki teknikte de her bir pencere elde edilmeden önce, orijinal resim ( $0^0-360^0$ ) arasında rastlantısal olarak çevrilmektedir; böylece, dokunun tümünü karakterize edecek şekilde çok değişik bölgelerinden yeterli

sayıda pencere elde edilmesi ve bu pencerelerden elde edilen doku öznelikleri ile döndürmeye duyarlı bir doku sınıflandırılması amaçlanmıştır.



Şekil 5. Piramit pencereleme ve örneği

### Yapay Sinir Ağı ile Doku Sınıflandırma

Yapay Sinir Ağları (YSA), mühendislik başta olmak üzere, bir çok alanda, doğrusal olmayan (*non-linear*) problemlerin çözümü üzerine yapılan araştırmalar da başarılı bir şekilde kullanıldığı görülmektedir. YSA'nın temel özelliklerinin başında, tamamıyla paralel, öğrenebilen, öğrenerek karar verme, uyarlamalı, ve paralel dağıtılmış bir hafızaya sahip olma gelir (*şekil-6*). Değişik öğrenme metodları arasında günümüzde en çok rağbet gören Geriye Yayımlı Algoritma (GYA)'dır (Rumelhart, Hinton and Williams, 1986).

Gizli katmandaki her bir işlem elemanından gönderilen sinyal değerleri,

$$S_{af} = \frac{1}{1+e^{-x}} \quad (5)$$

şeklinde bir aktivasyon fonksiyonu kullanıldığında

$$h_j = \frac{1}{1 + e^{-\sum_{i=0}^A W_{ij}^1 X_i}} \quad (j = 1, \dots, B) \quad (6)$$

formülü ile hesaplanır. Çıktı katmanındaki düğümlerden çıkan sinyal değerleri ise

$$o_k = \frac{1}{1 + e^{-\sum_{j=0}^B W_{jk}^2 h_j}} \quad (k = 1, \dots, C) \quad (7)$$

eşitliği ile verilir. Bir giriş ve çıkış çifti için hata

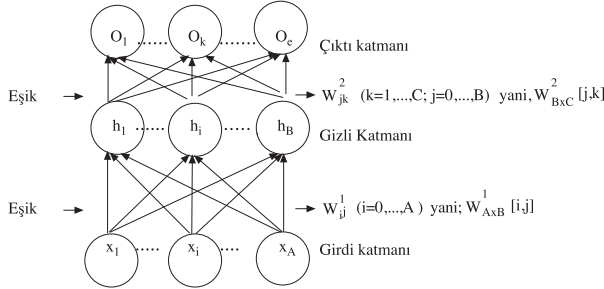
$$e = \frac{1}{2} \sum_{k=1}^c (y_k - o_k)^2 \quad (8)$$

şeklinde tanımlanır. Ortalama toplam hata ise

$$E = \frac{1}{2N} \sum_{l=1}^N \sum_{k=1}^c (y_k - o_k)^2 = \frac{1}{2N} \sum_i e_i \quad (9)$$

ifadesi ile hesaplanır.

GYA algoritmasında, ‘en dik iniş’ minimizasyon metodu ile, E değerini minimize eden optimum  $W^1$  ve  $W^2$  ağırlık değerlerinin (bkz. Şekil 6) bulunması amaçlanır. Metot ardışık şekilde çalışır. Genel olarak;  $t$ . iterasyonunda ağırlık değerleri için aşağıdaki bağıntı kullanılır.



Şekil 6. Çok katmanlı YSA yapısı:

$$W_{(t+1)} = W_t + \Delta W_{(t+1)} \quad (10)$$

Başlangıçta  $W_0$  değerleri rastgele olarak seçilir.  $\Delta W^1$  ve  $\Delta W^2$ 'nin hesaplanması için iki ayrı formül kullanılır.

$$\Delta W_{ij}^1(t+1) = -\eta \left( \frac{\partial e}{\partial W_{ij}^1} \right)_{t+1} + \alpha \Delta W_{ij}^1(t) \quad (11)$$

$$\Delta W_{jk}^2(t+1) = -\eta \left( \frac{\partial e}{\partial W_{jk}^2} \right)_{t+1} + \alpha \Delta W_{jk}^2(t) \quad (12)$$

Burada,  $\eta$ : öğrenme oranı;  $\alpha$ = momentum oranı olarak tanımlanmıştır. Yüksek  $\eta$  değeri öğrenme hızını artırır, fakat titreşimlere sebep olabilir. Öğrenmenin başında  $\eta$  için yüksek değer alınır; normal GYA ‘da  $\alpha$  sabit tutulur, adaptif GYA’da ise aşağıdaki algoritmaya göre değişime uğratılır:

$$E_{t+1} > \beta E_t \Rightarrow \alpha = \alpha \gamma \quad (13)$$

$$E_{t+1} < E_t \Rightarrow \alpha = \alpha \tau \quad (14)$$

Burada  $\beta$  maksimum hata oranı (varsayılan değeri: 1,04),  $\gamma$  öğrenme oranı azaltma katsayısı (varsayılan değeri: 0,7),  $\tau$  öğrenme oranı yükseltme

katsayısı (varsayılan değeri: 1,04). Momentum katsayısı pratikte 0,3-0,9 arasında alınır, en çok kullanılan momentum sabiti 0,7 dir. Sonuç olarak,

$$\Delta W_{ij}^1(t+1) = \eta \delta_j x_i + \alpha \Delta W_{ij}^1(t) \quad (15)$$

$$\Delta W_{jk}^2(t+1) = \eta \delta_k h_j + \alpha \Delta W_{jk}^2(t) \quad (16)$$

Burada,


$$\delta_k = -o_k (1 - o_k) (y_k - o_k) \quad (17)$$

$$\text{ve, } \delta_j = h_j (1 - h_j) \sum_{k=1}^c \delta_k W_{jk} \quad (18)$$

$W^1$  ve  $W^2$  ağırlıkları için güncelleştirme değerleri elde edilmiş olur. İterasyon önceden belirlenmiş bir hata değerine ininceye veya önceden belirlenmiş bir iterasyon sayısına kadar devam eder.

## Tartışma ve Sonuç

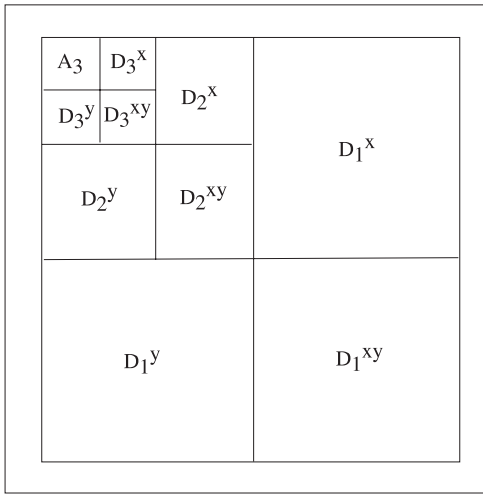
Çalışma, Brodatz albümünden 16 adet doku örneği ile yapıldı. Brodatz albümünden alınan doku örnekleri şekil-7’de görülmektedir. Birbirinden farklı olduğu kadar, birbirine oldukça benzeyen doku örneklerinin de seçilmesine dikkat edildi.



Şekil 7. Brodatz albümünden doku örnekleri (Brodatz,1966 ); **1:** Reptile Skin-D03(Timsah derisi), **2:** Grass lawn-D09(Çimen), **3:** Bark of tree-D12(Ağaç kabuğu), **4:** Herringbone weave-D17 (Yünlü kumaş), **5:** Pressed calf leather-D24 (dana derisi), **6:** Beach sand-D29 (Sahil kumu), **7:** Pressed cork-D32 (Mantar tıpa), **8:** Water-D38 (Su), **9:** Beach pebbles-D54 (Sahil çakılı), **10:** Straw matting-D55( Hasır), **11:** Wood grain-D68 (Ağaç damarı), **12:** Cotton canvas-D77 (Pamuklu kumaş), **13:** Raffia looped to a high pile-D84 (Hasır), **14:** Ceiling tile-D86 (Tavan), **15:** Clouds-D90 (Bulut), **16:** Fur. Hide of unborn calf-D93 (Yavru sığır derisi)

Her bir doku örneğinden 16 adet  $0^0$ - $360^0$  arasında rastgele döndürülmüş alt resim (pencere) elde edildi. Her bir dokudan elde edilen alt pencere-lerde 16 değişik rastgele açı kullanıldı. Burada 4 ayrı pencereleme tekniği; klasik “örtüşen” ve “örtüşmeyen” pencereleme teknikleri ve tarafımdan geliştirilen “Diyagonal” ve “Piramit” teknikleri, kullanıldı ve elde edilen performanslar karşılaştırıldı. Her bir alt-resmin Dalgacık dönüşümü yapıldı. Örneğin 3 skalalı ( $k=3$ ) dönüşümüyle elde edilen 4 adet doku özneteliği, *şekil-8*'de gösterilen  $A_3$ ,  $D_3^x$ ,  $D_3^y$  ve  $D_3^{xy}$  alt bandlarına ait enerji değerleridir. *Şekil-9* 2 skalalı dalgacık çerçeve dönüşümü ile elde edilen  $A_2$ ,  $D_2^x$ ,  $D_2^y$  ve  $D_2^{xy}$  alt bandlarına ait enerji görüntüsüdür.


Yapay sinir ağı yapısı *şekil-10*'de verilmiştir. Yapay sinir ağının giriş katmanındaki nöron sayısı 4 olup öznetelik sayısına eşittir. 4 öznetelik bir öznetelik vektörü oluşturmaktadır. Her bir doku örneğinden bu şekilde 16 adet öznetelik vektörü elde edildi. 16 doku örneğinden elde edilen 256 adet öznetelik vektörü yapay sinir ağının eğitilmesinde kullanıldı. Test işleminde, yukarıda bahsedilen işlemler baştan itibaren tekrarlandı; Dolayısıyla, eğitime ve test işlemlerinde, birbirinden bağımsız olarak elde edilmiş öznetelik vektör örnekleri kullanıldı.



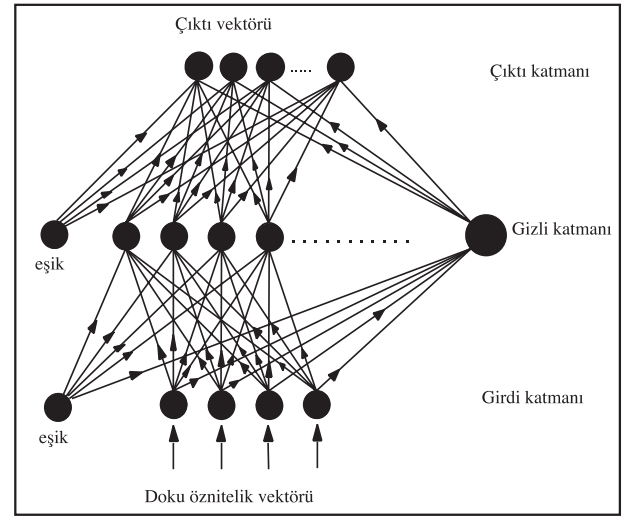
Şekil 8. Dalgacık dönüşümünde alt-bandlar

Gizli katmandaki nöron sayısı tesbiti için, öncelikle yüksek bir performans elde edilecek şekilde nöron sayısı yüksek tutuldu. Daha sonra, test performansı sabit kalmak üzere nöron sayısı kademeli olarak azaltıldı ve yüksek bir performans sağlayan minimum nöron sayısına ulaşıldı. Böylece aşırı

öğrenme riski önlenmiş oldu. Bilindiği gibi, gizli katmandaki nöron sayısı çok olması durumunda ortaya çıkabilen aşırı öğrenmede, eğitime performansı yüksek, test performansı ise, beklenilenin tersine, düşük olmaktadır.



Şekil 9. İki skalalı dalgacık çerçeve dönüşümünün  $A_2$ ,  $D_2^x$ ,  $D_2^y$  ve  $D_2^{xy}$



Şekil 10. Yapay sinir ağı yapısı

Çalışmada, dalgacık dönüşümünde değişik dalgacıklar kullanılarak, dalgacık türünün sınıflandırma performansı üzerindeki etkisi de araştırıldı. Öncelikle en basit dalgacık olması nedeniyle, Haar dalgacığı üzerinde duruldu.

Haar dalgacığı ve farklı pencereleme teknikleri ile elde edilen sonuçlar *Tablo-1*'de verilmiştir.

Bu tabloya göre en yüksek performans piramit pencereleme ile elde edildi. Klasik olarak uygulanan pencereleme tekniklerin performansları geliştirilen pencereleme tekniklerinden düşük olduğu için takip eden çalışmalar piramit pencereleme ile yapıldı.

**Tablo 1.** Farklı pencereleme tekniği ile Haar dalgacık , Eğitim-Test performans sonuçları (skala=3)

Pencereleme Tekniği	Eğitime	Test	CPU
Örtüşmeyen	95,7031	82,74	179
Örtüşen	96,851	92,86	210
Diyagonal	99,6094	94,92	231
Piramit	99,6094	98,72	185

Haar dalgacık üzerinde durulmuş olup, sonuçlar *Tablo-2'de* verilmiştir. Bu tabloya göre transform skalası 2 olduğunda, hemen hemen tam bir sınıflandırmaya tekabül eden % 99,9 gibi çok yüksek bir sınıflandırma performansı elde edilmiştir.

**Tablo 2.** Haar dalgacık ile Eğitim-Test performans sonuçları (Piramit)

Dalgacık Fonksiyon Ailesi	Dönüşüm Skala Sayısı	Eğitime %	Test %	CPU
Haar	3	100	98,72	250
Haar	2	100	99,90	235
Haar	1	100	99,60	237

Symlet ailesi ile skala sayısı 3 için elde edilen sonuçlar *Tablo-2.a'da* görülmektedir. Performans değerleri % 97 civarında olup, en yüksek değer Symlet(4) için % 97,65, en düşük değer Symlet(7) için % 97,06 dır.

**Tablo 2a.** Symlets dalgacık ailesi ile eğitim-test performans sonuçları (Piramit Pencereleme, skala=3)

Dalgacık Fonksiyon Ailesi	Eğitime %	Test %	CPU
Symlets(4)	99,60	97,65	267
Symlets(6)	99,60	97,35	351
Symlets(8)	99,60	97,06	396
Symlets(12)	99,60	97,06	581
Symlets(16)	99,60	97,45	757

Daubechies ailesi ile elde edilen sonuçlar *Tablo-2.b'de* Symlet ailesi ile hemen hemen aynı mertebelindedir.

**Tablo 2.b.** Daubechies dalgacık ailesi ile eğitim ve test performans sonuçları (skala 3)

Dalgacık Fonksiyon Ailesi	Eğitime %	Test %	CPU
Daubechies (4)	99,60	97,55	290
Daubechies (6)	99,60	97,65	337
Daubechies (8)	100	97,35	402
Daubechies (12)	100	97,26	519
Daubechies (16)	100	97,43	1070

En yüksek değer Daubechies(5) için % 97,65 ve en düşük değer Daubechies için % 97,26 dır. Burada kayda değer diğer bir önemli nokta ise, Daubechies serisinde  $N_{\text{sayısının}}$  artması ile doku öznelik elde etme CPU süresinin hızla artmasıdır. Lemarie ailesi ile elde edilen sonuçlar *Tablo-2.c'de*, Symlet ve Daubechies aileleri ile elde edilen sonuçlardan biraz daha düşük olup, Lemarie(14) için % 97,45'lik maksimum değere sahiptir. En düşük performans değeri Lemarie(4) için % 95,31 şeklindedir.

**Tablo 2.c.** Lemarie dalgacık ailesi ile eğitim ve test performans sonuçları (skala=3)

Dalgacık Fonksiyon Ailesi	Eğitime %	Test %	CPU
Lemarie(4)	98,04	95,31	264
Lemarie(6)	100	96,67	310
Lemarie(8)	100	96,67	393
Lemarie(12)	99,60	96,09	533
Lemarie(16)	99,60	97,45	762

Transform skalası 2 için Symlet ailesi ile elde edilen sonuçlar *Tablo-3.a'da* verilmiştir.

**Tablo-3.a.** Symlets dalgacık ailesi ile eğitim ve test performans sonuçları (skala=2)

Dalgacık Fonksiyon Ailesi	Eğitime %	Test %	CPU
Symlets(4)	100	99,86	232
Symlets(6)	100	99,86	295
Symlets(8)	100	99,73	277
Symlets(12)	100	99,21	292
Symlets(16)	100	99,08	338

En yüksek performans değeri, % 99,86 olarak Symlet(4) ve Symlet(5) ile elde edilmiş olup, bu değer Haar ile elde edilen değere oldukça yakındır. Symlet serisinde ilerledikçe performans değerinde bir düşüş gözlenmektedir.

Daubechies ailesinde en yüksek performans değeri Daubechies(4) için % 99,90 şeklinde *Tablo-3.b'de* verilmiş olup, Haar dalgacık ile elde edilen değere eşittir. Fakat doku öznelik elde etme (Pentium II PC, işlemci MMX-II, 233Mhz, RAM 64MB) CPU süresi 245 sn olup Haar durumundaki CPU süresinden (235 s) biraz daha yüksektir. Haar dalgacığın Daubechies(2)'ye eşdeğer olduğu dikkate alınrsa, Daubechies(2) ve Daubechies(4) arasında performans eşitliği olduğu söylenebilir. Bu ailede N sayısı artıkça performans düşmekte ve Daubechies(14) için % 98,82 olmaktadır.

Lemarie ailesi ile elde edilen sonuçlar ve Daubechies ailesi ile elde edilen sonuçlar biraz düşük olup, *Tablo-3.c'de* olduğu gibi ilginç bir durum arz etmektedir. Lemarie(2)'den Lemarie(10)'ye doğru bir performans artışı gözlenmekte ve % 99,60'lık değere ulaşmaktadır. Bunun yanında Lemarie(14) için performans düşmektedir.

**Tablo-3.b.** Daubechies dalgacık ailesi ile eğitime ve test performans sonuçları (skala=2)

Dalgacık Fonksiyon Ailesi	Eğitime %	Test %	CPU
Daubechies (4)	100	99,90	245
Daubechies (6)	100	99,73	266
Daubechies (8)	100	99,73	275
Daubechies (12)	100	99,47	306
Daubechies (16)	100	98,82	369

**Tablo 3.c.** Lemarie dalgacık ailesi ile eğitime ve test performans sonuçları (skala=2)

Dalgacık Fonksiyon Ailesi	Eğitime %	Test %	CPU
Lemarie(2)	98,04	97,26	234
Lemarie(4)	100	99,50	234
Lemarie(6)	100	99,51	244
Lemarie(8)	100	99,59	265
Lemarie(12)	100	99,60	367
Lemarie(16)	100	98,72	349

**Tablo 4.** Optimum şartlarda, test ile elde edilen doku sınıflandırma diagonal matrisi

	D03	D09	D12	D17	D24	D29	D32	D38	D54	D55	D68	D77	D84	D86	D90	D93
D03	16															
D09		16														
D12			16													
D17				16												
D24					16											
D29						16										
D32							16									
D38								16								
D54									16							
D55										16						
D68									1		15					
D77												16				
D84													16			
D86														16		
D90															16	
D93																16

D03(Timsah derisi), D09(Çimen), D12(Ağaç kabuğu), D17 (Yünlü kumaş), D24 (dana derisi), D29 (Sahil kumu), D32 (Mantar tıpa), D38 (Su), D54 (Sahil çakılı), D55( Hasır), D68 (Ağaç damarı), D77 (Pamuklu kumaş), D84 (Hasır), D86 (Tavan), D90 (Bulut), D93 (Yavru sığır derisi) (Şekil 7a bakınız)



Dalgacık transform metodu ile elde edilen sonuçlar topluca yorumlandığında şu genel hükümlere varılmaktadır: En yüksek sınıflandırma performansı Haar dalgacık ile elde edilmektedir. Aynı zamanda, doku öznelik elde etme CPU süresi Haar dalgacık için en düşük olmaktadır. Optimum transform skala sayısının ise 2 olduğu, ve dolayısıyla optimum doku öznelik sayısının 4 olduğu açık bir şekilde görülmektedir. Bu optimum şartlarda, test ile elde edilen doku sınıflandırma diagonal matrisi, *tablo-4'de* verilmiştir. Bu tablodaki (1:D03,...,16:D93) rumuzları *Şekil-7'de* verilen Brodatz albümündeki orijinal değerlere karşılık gelmektedir.

Burada bahsedilen test denemelerinden bağımsız olarak, doku örneklerinin tamamen rastgele olarak tek tek sunulduğu, "gerçek zaman uygulaması" çok sayıda test denemeleri de gerçekleştirilmiştir; bu

simulasyon denemelerinde, doku örneği tamamen rastlantısal olarak döndürülmüş, pencere tamamen rastlantısal bir boyutta oluşturulmuş ve % 100' çok yakın performanslar elde edilmiştir. Metodun başarısını pekiştirmek üzere, başka doku örnekleri ile çalışmanın genişletilmesi faydalı olacaktır.

### **Semboller:**

- a*: dilasyon parametresi
- b*: öteleme parametresi
- x*: dalgacık katsayısı
- $\psi$  : ana dalgacık
- $\phi$  : baba dalgacık
- $\beta$  : maksimum hata oranı
- $\alpha$  : momentum oranı
- $\gamma$  : öğrenme oranı azaltma katsayısı
- $\tau$  : öğrenme oranı yükseltme katsayısı

### **Kaynaklar**

- Akansu A.N., Smith, M.J.T, eds, Subband and Wavelet Transforms, Kluwer Press, 1995.
- Brodatz, P. Textures: A photographic album for artists and designers, Reinhold, New York, 1966.
- Chan, T. "Wavelet Basics", Royal Military College of Canada, 1996.
- Chen, J.L., Kundu, A. "Rotation and Gray Scale Transform Invariant Texture Identification Using Wavelet Decomposition and Hidden Markov Model", IEEE Trans. PAMI, 16(2): 208-214, 1994.
- Çetiner, B.G. "Techniques for Texture Analysis and Classification", PhD Thesis, Intelligent Systems Research Lab. School of Eng. Univ. of Wales, Cardiff, United Kingdom, 1995.
- Daubechies, I. Ten Lectures on Wavelets, Society for Industrial and Applied Mathematics, Capital City Press, Philadelphia, Pennsylvania, 1992.
- Meyer, Y. Wavelets: Algorithms and Applications, Philadelphia: SIAM, 1993.
- Pao, Y.H. Adaptive Pattern Recognition and Neural Networks, Addison-Wesley Publishing Company Inc. NY 1994.
- Porter, R., Canagarajah, N. "Rotation Invariant Texture Classification Schemes Using GMRFs and Wavelets", Proceedings IWISP'96; 4-7 Nov, 184-185, 1996.
- Rumelhart D., Hinton G. and Williams R. "Learning Internal Representations by Error Propagation", in Parallel Distributed Processing, Vol. 1, Eds. Rumelhart D. and McClelland, MIT Press, Cambridge, Mass., 1986.
- Strang, G., Nguyen, T. Wavelets and Filter Banks, Wellesley-Cambridge Press, ISBN 0-9614088-7-1 Box 812060, Wellesley MA 02181 USA, 1996.
- Unser, M. "Texture classification and segmentation using wavelet frames", IEEE Trans. Im. Proc., 4(11): 1549-1560, 1995.