

# BİYOMEDİKAL İŞARETLERİN SINIFLANDIRILMASINDA OTOMATİK TEŞHİS SİSTEMLERİNİN BAŞARIMI

**Elif Derya ÜBEYLİ**

Elektrik-Elektronik Müh. Bölümü, Mühendislik Fakültesi, TOBB Ekonomi ve Teknoloji Üniversitesi, 06530  
Söğütözü, Ankara  
[edubeyli@etu.edu.tr](mailto:edubeyli@etu.edu.tr)

(Geliş/Received: 24.08.2006; Kabul/Accepted: 05.04.2007)

## ÖZET

Bu çalışmada, oftalmik atardamar Doppler işaretlerinin, elektroensefalogram (EEG) ve elektrokardiyogram (EKG) işaretlerinin sınıflandırılması için farklı ve birleşik özniteliklerin kullanıldığı otomatik teşhis sistemleri incelenmiş ve bu sistemlerin doğrulukları saptanmıştır. Şekil tanımlama uygulamalarında, tanımlanacak olan işlenmemiş işaretten farklı öznitelikler çıkarılır. Farklı öznitelikleri olan birden fazla sınıflayıcıyı birleştirme, şekil sınıflamanın birçok alanında problem olarak görülmektedir. Birleşik öznitelikler ile eğitilen çok katmanlı perseptron sinir ağı, birleşik sinir ağı, uzman ağların karışımı ve farklı öznitelikler ile eğitilen değiştirilmiş uzman ağların karışımı gibi modellerin sınıflama doğrulukları karşılaştırılmıştır. Otomatik teşhis sistemlerinin girişleri, ağ yapılarına göre farklı veya birleşik özniteliklerden oluşmaktadır. Bu çalışmanın sonuçları, farklı öznitelikler ile eğitilen değiştirilmiş uzman ağların karışımı modelinin, birleşik öznitelikler ile eğitilen diğer otomatik teşhis sistemlerine göre yüksek doğruluk elde ettiğini göstermiştir.

**Anahtar Kelimeler:** Farklı öznitelikler, birleşik öznitelikler, biyomedikal işaretler, otomatik teşhis sistemleri.

## PERFORMANCE OF AUTOMATED DIAGNOSTIC SYSTEMS IN CLASSIFICATION OF BIOMEDICAL SIGNALS

### ABSTRACT

In this study, the automated diagnostic systems employing diverse and composite features for Doppler ultrasound signals, electroencephalogram (EEG) and electrocardiogram (ECG) signals were analyzed and their accuracies were determined. In pattern recognition applications, diverse features are extracted from raw data which needs recognizing. Combining multiple classifiers with diverse features are viewed as a general problem in various application areas of pattern recognition. The classification accuracies of multilayer perceptron neural network, combined neural network, and mixture of experts trained on composite feature and modified mixture of experts trained on diverse features were compared. The inputs of these automated diagnostic systems composed of diverse or composite features and were chosen according to the network structures. The conclusions of this study demonstrated that the modified mixture of experts trained on diverse features achieved accuracy rates which were higher than that of the other automated diagnostic systems trained on composite features.

**Keywords:** Diverse features, composite features, biomedical signals, automated diagnostic systems.

### 1. GİRİŞ (INTRODUCTION)

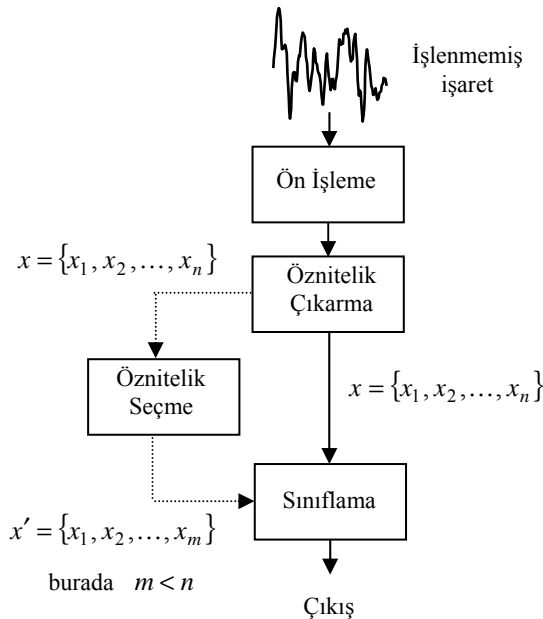
Teşhis sistemlerinde çeşitli yöntemler kullanılmakla birlikte teşhis sistemleri genellikle şu işlemlerden oluşmaktadır: ön işleme, öznitelik çıkarma/seçme ve sınıflama (Şekil 1). İşaret/görüntü elde etme, bozucu etkenlerin yok edilmesi, ortalama alma, eşik değeri belirleme, işaret/görüntü iyileştirme gibi işlemler ön

işlemeyi oluşturmaktadır. Öznitelik çıkarma, şekil tanımlama ve şeklin önemli özniteliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Öznitelik seçme isteğe bağlı olarak yapılan bir işlem olup sınıflama işlemi açısından en belirleyici özniteliklerin seçilmesi ile öznitelik vektörünün boyutunun azaltılmasıdır. Teşhis sistemlerinin son aşaması olan sınıflamada, kullanılan algoritmaya

bağlı olarak giriş öznitelik vektörleri incelenir ve sınıflama sonucu belirlenir. Sınıflama sonucunu belirlemesi açısından ele alındığında öznitelik çıkarma ve gerekli durumlarda öznitelik seçme, sınıflama sistemlerinin başarısını oldukça etkilemektedir [1-3].

Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabilir. İşlenmemiş işareti tanımlayan farklı öznitelikler elde edilebilmektedir. Çıkarılan her öznitelik vektörü işareti tanımlayabilir fakat sınıflama için hiç biri mükemmel olmayabilir. Ayrıca, şekil sınıflama işleminde özniteliklerin öneminin ölçümü kolay değildir. Bundan dolayı, yüksek sınıflama başarımı elde etmek için farklı özniteliklerin birlikte kullanımı gerekli olmuştur. Bu tip şekil sınıflama, farklı öznitelikler ile sınıflama olarak adlandırılır [4]. Sınıflama işlemi iki ayrı yöntem ile gerçekleştirilebilir. Bu yöntemlerden birinde farklı özniteliklerin bir araya getirilmesi ile oluşan birleşik öznitelikler kullanılırken, diğerinde farklı öznitelik vektörleri ile eğitilen birden fazla sınıflayıcı birleştirilir. Birleşik özniteliklerin kullanımından kaynaklanan birkaç problem aşağıda belirtilmektedir:

- Boyutu öznitelik vektör bileşenlerinden daha büyüktür ve boyutu büyük olan vektörler hesaplama karmaşıklığını artırdığı gibi gerçekleştirme ve doğruluk problemlerine neden olmaktadır.
- Farklı formlarda olan birkaç özneliği bir araya getirmek zordur, örneğin sürekli değişkenler, ikilik değerler, ayrık değişkenler, yapısal değişkenler.
- Öznitelik vektör bileşenleri genellikle bağımsız değildir.



**Şekil 1.** Teşhis sistemlerinde gerçekleştirilen işlemler (Processes performed in diagnostic systems)

Bu problemlerden dolayı birleşik özniteliklerin kullanımı genellikle başarıyı fazla yükseltmez. Bununla birlikte, farklı öznitelikleri içeren problemlerin çözümünde birden fazla sınıflayıcının birleşimi iyi bir çözüm olabilir. Karmaşık problemlerin çözümünde problemi basit parçalara bölüp daha sonra bu parçaların sonuçlarını tek bir çözümde birleştiren modeller üzerinde durulmaktadır. Bu yaklaşımı kullanan ve uzman ağların karışımı olarak adlandırılan birimsel sinir ağı modeli, Jacobs ve arkadaşları tarafından sunulmuştur [5]. Uzman ağların karışımı, uzman ağların çıkışlarını karıştırarak istenilen çıkışın şartlı olasılık yoğunluk işlevini modeller. Uzman ağların çıkışları, en iyi çözümü veren uzman ağı seçen ve aynı anda eğitilen geçit ağı ile birleştirilmektedir. Jordan ve Jacobs tarafından [6] belirtildiği gibi geçit ağı tipik çok sınıflı sınıflama işlemi gerçekleştirilmektedir. Uzman ağların karışımı modelinde, geçit ve uzman ağlara aynı giriş uygulanması gerektiği için birleşik öznitelikler kullanılabilir [7]. Chen tarafından sunulan [4] değiştirilmiş uzman ağların karışımı modeli farklı özniteliklerin kullanılabilirliği bir modeldir.

Durağan olmayan işaretlerin spektral analizi için uygun olmasından dolayı dalgacık dönüşümünün diğer spektral analiz metodlarına göre üstünlükleri vardır. Dalgacık dönüşümünün en önemli avantajı, düşük frekanslar için geniş, yüksek frekanslar için dar olacak şekilde değişen pencere boyutlarının olmasıdır. Böylece, bütün frekans aralıklarında optimum zaman-frekans çözünürlüğü sağlanabilmektedir [3,8-10]. Bu çalışmada zamanla değişen biyomedikal işaretlerin analizi dalgacık dönüşümü ile gerçekleştirilmiş ve dalgacık katsayıları işareti temsil eden öznitelik vektörleri olarak ele alınmıştır.

İncelenen biyomedikal işaretleri yüksek doğrulukla sınıflayabilmek için farklı ve birleşik öznitelikler ile eğitilen dört otomatik teşhis sistemi (farklı öznitelikler ile eğitilen değiştirilmiş uzman ağların karışımı; birleşik öznitelikler ile eğitilen çok katmanlı perseptron sinir ağı, birleşik sinir ağı ve uzman ağların karışımı) kullanılmıştır. Bu otomatik teşhis sistemlerinin başarımlarının değerlendirilmesinde toplam sınıflama doğrulukları ve ağ eğitiminin merkezi işlemci zamanı dikkate alınmıştır.

## 2. ANALİZİ YAPILAN BİYOMEDİKAL İŞARETLER (ANALYZED BIOMEDICAL SIGNALS)

Ultrasonik Doppler, kan akış hızını, yönünü ve debisini incelemeye kullanılmaktadır. Doppler sistemlerinde, ultrasonik dönüştürücünün gönderdiği ultrasonik dalganın kandaki kırmızı kan hücrelerinden saçılması ve yansımından dolayı frekansta değişimler gözlenir. Doppler kayma frekansı, damara gönderilen dalganın frekansı ile yansıyan dalganın frekansı arasındaki farktır:

$$f_D = f_t - f_r = \frac{2f_t v \cos \theta}{c} \quad (1)$$

burada,  $f_D$  Doppler kayma frekansı,  $f_t$  damara gönderilen dalganın frekansı,  $f_r$  damardan yansıyan dalganın frekansı,  $v$  kandaki parçacıkların hızı,  $c$  ultrasonik dalganın ortamdaki hızı,  $\theta$  ultrasonik dalga ile parçacıkların hareket yönü arasındaki açıdır [3,7]. Ultrasonik dalganın kandan saçılması tek ve aynı hızda hareket eden parçacıklardan olmadığı için Doppler frekansı spektrum şeklinde gözlenir. Doppler güç spektrumunun şekli ile ölçüm yapılan bölgedeki kan hızının şekli benzerdir. Bu durumda, Doppler işaretlerinin spektral analizi ile atardamarlardaki hız dağılımı hakkında bilgi elde edilebilir. Spektral analiz metodlarının kullanılması ile Doppler işaretlerinin güç yoğunluk spektrumlarının kestirimi yapılır ve tıbbi bilgi elde etmek için Doppler spektrumlarındaki değişimler incelenir. Doppler işaretlerinin spektral içeriğinden kan akışı ile ilgili sonuçlar çıkarılabilir. Spektral şeklin ve parametrelerin analizi ile işaretin sağlıklı veya hastalıklı atardamara ait olduğu belirlenir [3,7].

Oftalmik atardamar göze ve göz küresinin bulunduğu göz çukuruna kan sağlar. Oftalmik atardamarın boyutlarındaki ve kan akış hızındaki değişiklikler ve oftalmik atardamarın direncindeki artışlar Behçet hastalığının belirtilerindedir. Bu belirtilerle birlikte görülen Behçet hastalığı görme kaybına neden olduğu için hastalığın erken teşhisi önemlidir [3,7]. Bu çalışmada, sağlıklı, oftalmik atardamar daralması ve Behçet hastalığı olan kişilere ait oftalmik atardamar Doppler işaretlerinin spektral analizi dalgacık dönüşümü ile gerçekleştirilmiştir.

Elektroensefalogram (EEG) işaretleri, beyin fonksiyonlarının elektriksel olarak değişimini ifade eder. Beynin işlevsel durumuna göre örneğin; uykuda, anesteziye, oksijen eksikliği (hipoksia) durumunda ve epilepsi gibi belirli sinir hastalıklarında, bu aktivite değişmektedir. EEG ilk kayıt edilmeye başlandığından beri klinik uygulamalarda en önemli teşhis araçlarından biri olmuştur [11,12]. EEG işaretleri, hastalık teşhisinin doğruluğunu sağlamak için çoğunlukla 8-10 saatlik kayıtlar şeklinde alınmaktadır. EEG kayıtlarının bu şekilde uzun olmasından dolayı, EEG işaretlerinin analizinin bilgisayar ortamında yapılması gerekli olmuştur. Bu konuda farklı yöntem ve algoritmalar geliştirilmiştir [11,12]. Bu çalışmada, kaynak [13]'te tanımlanan farklı kişilerden kayıt edilmiş EEG işaretlerinin (sağlıklı kişilerden – grup A, epilepsi nöbetinin olmadığı durumda epilepsi hastalarından – grup D ve epilepsi nöbeti sırasında epilepsi hastalarından kayıt edilen EEG işaretleri – grup E) spektral analizi dalgacık dönüşümü ile gerçekleştirilmiştir.

Elektrokardiyogram (EKG) işaretleri, kardiyak sistemin biyoelektrik ve biyomekanik aktivitelerinin

kayıtlarıdır. Bu işaretler, kardiyovasküler sistem ve kalbin fonksiyonları hakkında önemli bilgi içermektedir. Kayıt edilen EKG'lerin normal EKG'lerle karşılaştırılmasıyla, kalbin çalışmasıyla ilgili bazı normal dışı durumlar belirlenebilir. Bir doktorun hastada yapılmasını istediği temel ölçümlerden birisi EKG ve kalp vuru hızının ölçümüdür. EKG'de her kalp atımının karşılığı olan P,Q,R,S,T dalgalarından oluşmuş bir kompleks görülür. Bu dalgalardaki değişiklikler, düzenli dalgalardan farklı dalgalardan görülmesi, dalgalardan arasındaki sürelerdeki değişimler doktorlara kalp hastalığı hakkında ipuçları verirler [14-16]. Kalp yetersizliği kalbin vücut ihtiyacını karşılayabilecek kadar kan pompalayamaması durumunda oluşur. Konjestif kalp yetersizliği olarak bilinen bu durumda toplar damarlarda, vücut dokularında ve akciğerlerde sıvı birikir ve ödem oluşur. Vücut fazla miktardaki suyu atamaz. Kalp çok yavaş veya çok hızlı, düzenli veya düzensiz atabilir. Enfarktüs geçirmiş, kalp damarlarında daralma olan veya herhangi başka bir kalp hastalığı geçirmiş kişilerde ventriküler taşiaritmi (hızlı aritmi) görülebilir. Atrial fibrilasyon en sık gözlenen ritim bozukluklarından biridir. Atrial fibrilasyonda uyarılar atriumda düzgün bir şekilde yol alacaklarına atrium içinde aynı anda sayısız uyarı dalgası oluşup farklı yönlerde hareket eder ve atrioventriküler düğümünden geçmek için birbirleriyle yarışır. Bu uyarılar kalbin elektriksel sistemi dışındaki dokulardan kaynaklanır. Bu uyarıların oluşması ile çok hızlı ve organize olmayan bir kalp ritmi oluşur [14-16]. Bu çalışmada kaynak [17]'den elde edilen, normal, konjestif kalp yetersizliği, ventriküler taşiaritmi ve atrial fibrilasyon durumlarındaki EKG işaretlerinin spektral analizi dalgacık dönüşümü ile gerçekleştirilmiştir.

### 3. OTOMATİK TEŞHİS SİSTEMLERİ (AUTOMATED DIAGNOSTIC SYSTEMS)

#### 3.1. Birleşik Sinir Ağı (Combined Neural Network)

Bu modelin temelinde yığılı genelleştirme kavramı yer almaktadır. Yığılı genelleştirme kavramı Wolpert tarafından [18] ortaya atılmış ve son çıkışın kestirimi için bir küme genelleştiricinin diğerlerini beslemesini göstermektedir. Genelleştiricilerin beslediği bilgi, orjinal eğitim verisinin çoklu parçalarından elde edilmektedir. Yığılı genelleştirme, çapraz geçerliliğin daha karmaşık şekli gibi görülebilir ve tekli yapıdaki sinir ağları ile karşılaştırıldığında genelleştirme özelliğinin daha yüksek olduğu ortaya çıkmaktadır [16,19]. Bu çalışmadaki birleşik sinir ağlarının oluşturulmasında, birinci ve ikinci seviyede çok katmanlı perseptron sinir ağı kullanılmıştır. Birleşik sinir ağlarının bu şekilde oluşturulmasının nedenleri; çok katmanlı perseptron sinir ağlarının öğrenme ve genelleştirme yeteneklerinin fazla olması, küçük eğitim verisine ihtiyaç duymaları, hızlı işlem yapabilmeleri ve gerçekleştirilmelerinin kolay olmasıdır. Birinci ve ikinci seviyedeki ağların

eğitiminde Levenberg-Marquardt algoritması kullanılmıştır.

### 3.2. Uzman Ağların Karışımı (Mixture of Experts)

Uzman ağların karışımı modelinde bir geçit ağı ve birkaç uzman ağ bulunmaktadır. Bu modelde bir sınıflama probleminin daha basit alt sınıflama problemlerine bölünmesi ve işlemin bu şekilde gerçekleştirilmesi için küçük uzman ağlar kullanılmaktadır. Geçit ağı  $\mathbf{x}$  vektörünü giriş olarak alır ve sayısal çıkışları oluşturur. Her bir uzman ağ, giriş vektörüne karşı çıkış vektörü oluşturur. Geçit ağı uzman ağların olasılıkları için katsayıların doğrusal kombinasyonunu belirler ve uzman ağların karışımı modelindeki son çıkış, uzman ağların çıkış vektörlerinin ağırlıklı toplamıdır. Uzman ağların karışımı modelinde  $N$  adet uzman ağ olduğu varsayımı yapıldığında,  $i$ 'inci uzman ağ  $\mathbf{o}_i(\mathbf{x})$  çıkışını giriş vektörü  $\mathbf{x}$ 'in genelleştirilmiş doğrusal işlevi olarak oluşturur [7]:

$$\mathbf{o}_i(\mathbf{x}) = f(\mathbf{W}_i \mathbf{x}) \quad (2)$$

burada  $\mathbf{W}_i$  ağırlık matrisi ve  $f(\cdot)$  sabit sürekli doğrusal olmayan işlevdir. Geçit ağı doğrusal işlevi genelleştirir ve  $i$ 'inci çıkış şu şekilde belirtilir:

$$g(\mathbf{x}, \mathbf{v}_i) = \frac{e^{\xi_i}}{\sum_{k=1}^N e^{\xi_k}} \quad (3)$$

burada  $\xi_i = \mathbf{v}_i^T \mathbf{x}$  ve  $\mathbf{v}_i$  ağırlık vektörüdür. Uzman ağların karışımı modelinin son çıkışı şu şekilde ifade edilir:

$$\mathbf{o}(\mathbf{x}) = \sum_{k=1}^N g(\mathbf{x}, \mathbf{v}_k) \mathbf{o}_k(\mathbf{x}). \quad (4)$$

Uzman ağların karışımı modelinin olasılık modeline bağlı olarak eğitimi enbüyük olasılık problemi olarak ele alınabilir. Jordan ve Jacobs [6] modelin parametrelerinin ayarlanabilmesi için beklenen değeri enbüyüklemeye algoritmasını geliştirmişlerdir.

### 3.3. Değiştirilmiş Uzman Ağların Karışımı (Modified Mixture of Experts)

Değiştirilmiş uzman ağların karışımı modeli,  $N$  adet uzman ağ ve geçit ağlarından oluşmaktadır.  $K$  adet ayrı öznelik olması durumunda uzman ağlar,  $K$  gruba bölünür ve  $i$ 'inci grupta  $N_i$  adet uzman ağ

$$\sum_{i=1}^K N_i = N \text{ formuna dönüşür. Aynı gruptaki uzman}$$

ağlar aynı öznelik vektörlerini giriş olarak kullanırken farklı gruplardaki herhangi iki uzman ağ farklı öznelik vektörlerini giriş olarak kullanır. Bir giriş örneği için her uzman ağ özneliklere bağlı olarak çıkış vektörünü oluşturur.  $K$  adet geçit ağı için  $K$  adet öznelik vektörü bulunmaktadır. Her geçit ağı özneliklere bağlı olarak çıkış vektörünü

oluşturur. Çıkış vektörü  $N$  bileşenden oluşmaktadır ve her bir bileşen bir uzman ağa karşılık gelmektedir. Geçit ağlarının son çıkışı bütün geçit ağlarının oluşturduğu çıkışların ağırlıklı toplamıdır ve farklı özneliklerden oluşan girişlere bağlı olarak ortaya çıkmaktadır. Değiştirilmiş uzman ağların karışımı modelindeki son çıkış,  $N$  adet uzman ağın çıkışının geçit çıkışı ile ağırlıklandırılmış doğrusal kombinasyonudur. Bu modelde iki yarış mekanizması vardır; uzman ağlar eğitim verisini öğrenme hakkını elde etmek için yarışırken farklı öznelikleri olan geçit ağları çıkışı oluşturacak olan uygun uzman ağı seçme hakkını elde etmek için yarışır. Bu modelde parametre kestirimi enbüyük olasılık öğrenme problemidir [4]. Beklenen değeri enbüyüklemeye algoritması problemi çözmek için kullanılmıştır. Bu çalışmada, geçit ve uzman ağlar çok katmanlı perseptron sinir ağlarından oluşturulmuştur.

### 4. DALGACIK DÖNÜŞÜMÜ (WAVELET TRANSFORM)

Dalgacık dönüşümü sürekli ve ayrık olmak üzere iki farklı şekilde incelenir. Sürekli dalgacık dönüşümünde ölçeklendirme ve dönüşüm parametrelerinin sürekli olarak değişiminden dolayı her bir ölçek için dalgacık katsayılarının hesaplanması zor ve zaman alıcı olmaktadır. Bu nedenle ayrık dalgacık dönüşümü daha sık kullanılmaktadır. Dalgacık dönüşümü ile işaret belli sayıda ölçeklere ayrılır. Çoklu çözünürlük ayrışımı olarak isimlendirilen bu işlem,  $x(n)$  işareti için Şekil 2'de gösterilmektedir. Şekil 2'de, ilk yüksek geçiren filtreye ( $g[\cdot]$ ) ve alçak geçiren filtreye ( $h[\cdot]$ ) ait olan örneklenmiş çıkışlar sırası ile ayrıntılı  $D_1$  ve yaklaşık  $A_1$  alt bandlarını oluşturur.  $A_1$  yaklaşım bandı tekrar ayrıştır ve bu işlem Şekil 2'de görüldüğü gibi devam eder. Dalgacık dönüşümü aşağıda verilen şartı sağlayan alçak geçiren filtre ( $h$ ) ile belirtilebilir:

$$H(z)H(z^{-1}) + H(-z)H(-z^{-1}) = 1 \quad (5)$$

burada  $H(z)$ ,  $h$  filtresinin  $z$ -dönüşümüdür. Bu filtrenin tamamlayıcı yüksek geçiren filtresi ( $g$ ) şu şekilde tanımlanabilir:

$$G(z) = zH(-z^{-1}) \quad (6)$$

Artan uzunluklar ile filtre dizisi ( $i$  indeksi ile) şu şekilde elde edilir:

$$H_{i+1}(z) = H(z^{2^i})H_i(z) \quad (7)$$

burada başlangıç şartı  $H_0(z) = 1$ 'dir. Bu, zaman bölgesinde şu şekilde ifade edilir:

$$h_{i+1}(k) = [h]_{\uparrow 2^i} * h_i(k) \quad (8)$$

burada,  $[\cdot]_{\uparrow m}$  indeksi  $m$  faktörü ile yukarı örnekleme yapıldığını gösterir ve  $k$  eşit olarak örneklenmiş ayrık zamanı belirtir. Normalize edilmiş dalgacık ve

ölçek temelli fonksiyonlar  $\varphi_{i,l}(k)$ ,  $\psi_{i,l}(k)$  şu şekilde tanımlanır:

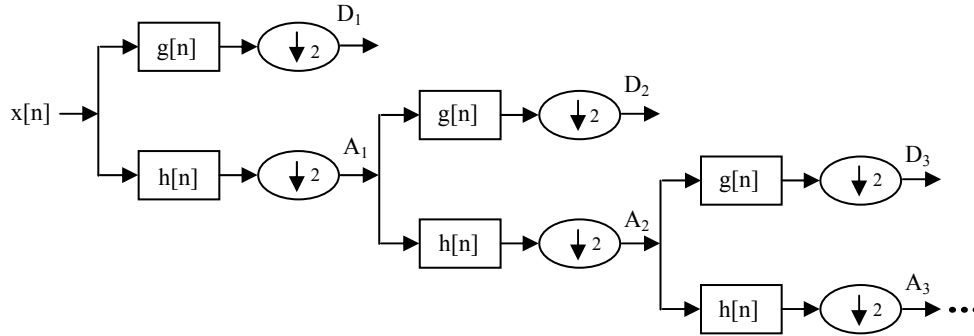
$$\begin{aligned}\varphi_{i,l}(k) &= 2^{i/2} h_i(k - 2^i l) \\ \psi_{i,l}(k) &= 2^{i/2} g_i(k - 2^i l)\end{aligned}\quad (9)$$

burada,  $2^{i/2}$  faktörü iç çarpım normalizasyonudur,  $i$  ölçeklendirme parametresi,  $l$  dönüşüm

parametresidir. Ayrık dalgacık dönüşüm ayrışımı şu şekilde belirtilir:

$$\begin{aligned}a_{(i)}(l) &= x(k) * \varphi_{i,l}(k) \\ d_{(i)}(l) &= x(k) * \psi_{i,l}(k)\end{aligned}\quad (10)$$

burada,  $a_{(i)}(l)$  ve  $d_{(i)}(l)$  sırası ile  $i$  çözünürlüğündeki yaklaşık katsayılar ve ayrıntılı katsayılardır [3,8-10].



**Şekil 2.** Ayrık dalgacık dönüşümünün gerçekleştirilmesinde alt bandlara ayrışım;  $g[n]$  yüksek geçiren filtre,  $h[n]$  alçak geçiren filtre (Subband decomposition of discrete wavelet transform implementation;  $g[n]$  is the high-pass filter,  $h[n]$  is the low-pass filter)

## 5. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

### 5.1. Farklı Öznitelik Vektörlerinin Hesaplanması (Computation of Diverse Feature Vectors)

Uygun dalgacık seçimi ve ayrışım seviyelerinin sayısının tesbiti, işaretlerin dalgacık dönüşümü ile analizinde oldukça önemlidir. İşaretin baskın frekans bileşenlerine göre ayrışım seviyelerinin sayısı tespit edilir. Bu çalışmada analizi yapılan biyomedikal işaretler, 256 örnekten oluşan bölütlere ayrılmıştır. Doppler işaretleri 40 Hz'in altında önemli frekans bileşenlerine sahip olmadığı için ayrışım seviyelerinin sayısı 7 olarak belirlenmiştir. Bu durumda, Doppler işaretleri  $D_1 - D_7$  ayrıntılı alt bandlarına ve son olarak  $A_7$  yaklaşık alt bandına ayrılmıştır.  $A_7$  alt bandındaki katsayılar sıfıra çok yakın olduğu için bu banddaki katsayılar öznitelik olarak ele alınmamıştır. Sınıflamanın doğruluğu uygulama için seçilen dalgacık tipine bağlıdır. Doppler işaretlerinin dalgacık katsayılarının hesaplanmasında 1. dereceden Daubechies dalgacık (db1) kullanımının uygun olduğu belirlenmiştir.

EEG ve EKG işaretlerinin ayrışım seviyelerinin sayısı 4 olarak tespit edilmiştir. Bu durumda, EEG ve EKG işaretleri  $D_1 - D_4$  ayrıntılı alt bandlarına ve son olarak  $A_4$  yaklaşık alt bandına ayrılmıştır. EEG ve EKG işaretlerinin dalgacık katsayılarının hesaplanmasında 2. dereceden Daubechies dalgacık (db2) kullanımının uygun olduğu belirlenmiştir.

Dalgacık katsayılarının hesaplanmasında MATLAB program paketi kullanılmıştır.

Her bir Doppler bölümü için 254 dalgacık katsayısı ve EEG, EKG bölümleri için 265 dalgacık katsayısı elde edilmiştir. Çıkarılan öznitelik vektörlerinin boyutlarının azaltılabilmesi için dalgacık katsayıları üzerinde aşağıda belirtilen istatistiksel özellikler kullanılmıştır:

1. Her bir alt banddaki dalgacık katsayılarının enbüyüğü,
2. Her bir alt banddaki dalgacık katsayılarının ortalaması,
3. Her bir alt banddaki dalgacık katsayılarının enküçüğü,
4. Her bir alt banddaki dalgacık katsayılarının standard sapması.

Oftalmik atardamar Doppler işaretlerinin, EEG ve EKG işaretlerinin farklı sınıflarına ait örnek işaretleri için hesaplanan dalgacık katsayıları Tablo 1-3'te verilmektedir. Bu tablolardan görüldüğü gibi farklı sınıflara ait işaretlerden hesaplanan dalgacık katsayıları işaretleri ayırt edici özelliktedirler.

### 5.2. Otomatik Teşhis Sistemlerinin Biyomedikal İşaretlere Uygulanması (Application of Automated Diagnostic Systems to Biomedical Signals)

Oftalmik atardamar Doppler işaretleri 169 kişiden (sağlıklı, oftalmik atardamar daralması ve Behçet hastası olan kişiler) kayıt edilmiştir. Ağ modellerinin eğitimi için 60 kişiye ait Doppler bölümü (her sınıftan

20 bölüt), 600 EEG bölütü (her sınıftan 200 bölüt), 360 EKG bölütü (her sınıftan 90 bölüt) ve testi için 109 kişiye ait Doppler bölütü (43 sağlıklı, 32 oftalmik atardamar daralması, 34 Behçet hastası), 600 EEG bölütü (her sınıftan 200 bölüt), 360 EKG bölütü (her sınıftan 90 bölüt) kullanılmıştır.

Değiştirilmiş uzman ağların karışımı modelinde uzman ağlar dört farklı öznelik vektörünün uygulandığı dört gruba bölünmüştür. Aynı sınıflama problemi için uzman ağlardan oluşan ve birleşik öznelik vektörleri ile eğitilen uzman ağların karışımı modeli geliştirilmiştir. Gerçekleştirilen birleşik sinir ağı modelinde ilk seviyede işaretlerin sınıf sayısı kadar sinir ağı eğitilmiştir. Her bir ağı bir tip

sınıflamayı diğerlerine göre daha doğru yapacak şekilde eğitilmektedir. Ağın mimarisinde çok katmanlı perseptron sinir ağları yer almaktadır. Her bir ağın girişi birleşik öznelik vektör boyutu kadar nörondan oluşmaktadır. Birinci seviyedeki ağ çıkışlarını birleştiren ikinci seviyedeki sinir ağları eğitilmiştir. İkinci seviyedeki ağların girişi, birinci seviyedeki ağların çıkışlarından oluşmaktadır. Farklı sınıflayıcıların başarımlarını karşılaştırmak amacı ile aynı sınıflama problemi için birleşik öznelik vektörleri ile eğitilen çok katmanlı perseptron sinir ağları geliştirilmiştir. Biyomedikal işaretlerin sınıflandırılmasında kullanılan sinir ağı modelleri, MATLAB program paketi ile gerçekleştirilmiştir.

**Tablo 1.** Üç farklı sınıfa ait oftalmik atardamar Doppler işaretlerinden hesaplanan dalgacık katsayıları  
(Computed wavelet coefficients of ophthalmic arterial Doppler signals belonging to three different classes)

Doppler işaretleri	Öznelikler	Dalgacık katsayıları						
		Alt bandlar						
		D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	D <sub>5</sub>	D <sub>6</sub>	D <sub>7</sub>
Sağlıklı	Enbüyük	46.6690	129.5000	64.3467	66.0000	115.6120	242.1250	520.3422
	Ortalama	-0.6187	2.0469	5.0823	1.0312	35.6205	63.5000	436.0197
	Enküçük	-	-59.5000	-70.7107	-42.5000	-69.1197	-	351.6972
	Standard sapma	37.4767	17.9378	32.6882	43.9119	31.7957	69.8398	181.9475
Daralma	Enbüyük	13.4350	38.5000	91.2168	168.2500	258.4475	30.6250	177.9257
	Ortalama	0.0829	0.6953	2.2208	6.7969	22.6495	-82.2188	76.1466
	Enküçük	-	-52.5000	-	-	-	-	-25.6326
	Standard sapma	18.3848	6.3019	17.2879	48.3056	74.1666	209.7461	108.3885
Behçet hastalığı	Enbüyük	9.8995	28.0000	75.6604	167.2500	253.1442	188.0000	5.4801
	Ortalama	-0.1713	-0.6172	-0.7844	-1.2656	-8.5074	-6.9687	-36.7254
	Enküçük	-9.1924	-24.5000	-69.2965	-	-	-	-78.9308
	Standard sapma	3.7508	10.7067	30.1504	81.9287	140.8417	190.4275	59.6875

**Tablo 2.** Üç farklı sınıfa ait EEG işaretlerinden hesaplanan dalgacık katsayıları  
(Computed wavelet coefficients of EEG signals belonging to three different classes)

EEG işaretleri	Öznelikler	Dalgacık katsayıları				
		Alt bandlar				
		D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	A <sub>4</sub>
Grup A	Enbüyük	12.0394	31.3064	75.7695	120.0146	192.6771
	Ortalama	-0.2611	0.1775	1.6022	2.1703	34.4130
	Enküçük	-12.0140	-42.0737	-92.3744	-105.3666	-172.4994
	Standard sapma	4.9689	14.8416	41.1865	60.3469	96.4623
Grup D	Enbüyük	26.0292	117.9646	32.3480	88.2469	320.4451
	Ortalama	-0.1935	0.1121	-2.2112	-2.6360	94.1584
	Enküçük	-20.6820	-82.1600	-61.5424	-89.1512	-175.7673
	Standard sapma	4.3874	19.2455	20.1756	43.6354	126.3576
Grup E	Enbüyük	258.0806	644.3659	1524.4000	1420.1000	1639.2000
	Ortalama	-0.1337	0.1052	65.5614	-77.2298	281.4010
	Enküçük	-325.4508	-1074.6000	-1508.9000	-1107.0000	-1917.6000
	Standard sapma	75.1448	303.6744	716.0870	614.2615	1138.5000

**Tablo 3.** Dört farklı sınıfa ait EKG işaretlerinden hesaplanan dalgacık katsayıları  
(Computed wavelet coefficients of ECG signals belonging to four different classes)

EKG işaretleri	Öznitelikler	Dalgacık katsayıları				
		Alt bandlar				
		D <sub>1</sub>	D <sub>2</sub>	D <sub>3</sub>	D <sub>4</sub>	A <sub>4</sub>
Normal	Enbüyük	0.2062	1.5757	0.2792	0.9683	0.5843
	Ortalama	-0.0003	0.0429	-0.0269	0.1097	-0.0941
	Enküçük	-0.1814	-0.3593	-0.3977	-0.3625	-0.5159
	Standard sapma	0.0436	0.3174	0.1546	0.3707	0.3116
Konjestif kalp yetersizliği	Enbüyük	0.1316	0.2344	1.3364	1.3463	1.1550
	Ortalama	-0.0003	-0.0066	-0.0056	-0.0248	-0.3698
	Enküçük	-0.1119	-0.1635	-1.0327	-1.9773	-1.2350
	Standard sapma	0.0259	0.0604	0.3995	0.7862	0.4014
Ventriküler taşiaritmi	Enbüyük	0.1568	0.4554	2.1134	2.5063	4.1980
	Ortalama	-0.0001	0.0002	0.0344	0.0838	0.9075
	Enküçük	-0.0839	-0.3181	-0.8983	-1.4226	-0.5930
	Standard sapma	0.0232	0.0919	0.4845	0.8299	1.1458
Atrial fibrilasyon	Enbüyük	0.0665	0.4417	0.3574	1.3044	-0.9396
	Ortalama	-0.0002	0.0037	-0.0058	0.0774	-1.5942
	Enküçük	-0.0564	-0.1832	-0.3312	-0.3328	-2.0488
	Standard sapma	0.0173	0.0849	0.1238	0.4051	0.2892

**Tablo 4.** Sınıflayıcıların ağ parametreleri (Network parameters of classifiers)

Biyomedikal işaretler	Sınıflayıcı (öznitelik)	Ağ parametreleri
Oftalmik atardamar Doppler işaretleri	Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	7·25·3 <sup>a</sup> , 7·25·3 <sup>a</sup> , 7·25·3 <sup>a</sup> , 7·25·3 <sup>a</sup> , 7·25·3 <sup>b</sup> , 7·25·3 <sup>b</sup> , 7·25·3 <sup>b</sup> , 7·25·3 <sup>b</sup> , 600 <sup>c</sup>
	Uzman ağların karışımı (birleşik öznitelikler)	28·25·3 <sup>a</sup> , 28·25·3 <sup>d</sup> , 800 <sup>c</sup>
	Birleşik sinir ağı (birleşik öznitelikler)	28·30·9 <sup>e</sup> , 9·30·3 <sup>f</sup> , 1800 <sup>c</sup>
	Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	28·25·3 <sup>g</sup> , 2700 <sup>c</sup>
EEG işaretleri	Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	5·30·3 <sup>a</sup> , 5·30·3 <sup>a</sup> , 5·30·3 <sup>a</sup> , 5·30·3 <sup>a</sup> , 5·30·3 <sup>b</sup> , 5·30·3 <sup>b</sup> , 5·30·3 <sup>b</sup> , 5·30·3 <sup>b</sup> , 700 <sup>c</sup>
	Uzman ağların karışımı (birleşik öznitelikler)	20·30·3 <sup>a</sup> , 20·30·3 <sup>d</sup> , 800 <sup>c</sup>
	Birleşik sinir ağı (birleşik öznitelikler)	20·30·9 <sup>e</sup> , 9·30·3 <sup>f</sup> , 2000 <sup>c</sup>
	Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	20·30·3 <sup>g</sup> , 2600 <sup>c</sup>
EKG işaretleri	Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	5·20·4 <sup>a</sup> , 5·20·4 <sup>a</sup> , 5·20·4 <sup>a</sup> , 5·20·4 <sup>a</sup> , 5·20·4 <sup>b</sup> , 5·20·4 <sup>b</sup> , 5·20·4 <sup>b</sup> , 5·20·4 <sup>b</sup> , 800 <sup>c</sup>
	Uzman ağların karışımı (birleşik öznitelikler)	20·25·4 <sup>a</sup> , 20·25·4 <sup>d</sup> , 900 <sup>c</sup>
	Birleşik sinir ağı (birleşik öznitelikler)	20·20·16 <sup>e</sup> , 16·20·4 <sup>f</sup> , 1900 <sup>c</sup>
	Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	20·25·4 <sup>g</sup> , 2800 <sup>c</sup>

<sup>a</sup>Uzman ağların tasarımı: Giriş · gizli · çıkış nöronları<sup>c</sup>Eğitim ardışıklarının sayısı<sup>e</sup>Birinci seviyedeki ağ tasarımı: Giriş · gizli · çıkış nöronları<sup>f</sup>Sinir ağı tasarımı: Giriş · gizli · çıkış nöronları<sup>b</sup>Geçit ağlarının tasarımı: Giriş · gizli · çıkış nöronları<sup>d</sup>Geçit ağının tasarımı: Giriş · gizli · çıkış nöronları<sup>f</sup>İkinci seviyedeki ağ tasarımı: Giriş · gizli · çıkış nöronları

**Tablo 5.** Toplam sınıflama doğrulukları ve eğitim için merkezi işlemci zamanı  
(Total classification accuracies and central processing unit times for training)

Biyomedikal işaretler	Sınıflayıcı (öznitelikler)	Toplam sınıflama doğruluğu (%)	Merkezi işlemci zamanı (dak:s)
Oftalmik atardamar Doppler işaretleri	Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	97.25	9:25
	Uzman ağların karışımı (birleşik öznitelikler)	95.41	11:16
	Birleşik sinir ağı (birleşik öznitelikler)	94.50	15:42
	Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	90.83	18:08
EEG işaretleri	Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	98.17	10:37
	Uzman ağların karışımı (birleşik öznitelikler)	97.33	13:25
	Birleşik sinir ağı (birleşik öznitelikler)	95.00	15:23
	Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	90.83	19:06
EKG işaretleri	Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	98.61	9:42
	Uzman ağların karışımı (birleşik öznitelikler)	96.39	10:53
	Birleşik sinir ağı (birleşik öznitelikler)	94.44	13:58
	Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	91.11	18:41

Farklı biyomedikal işaretler için geliştirilmiş olan ağ modellerinin eğitim ardışıklarının sayısı ve ağ parametreleri Tablo 4’te verilmektedir. Ardışım sayıları incelendiğinde değiştirilmiş uzman ağların karışımı ve uzman ağların karışımı modellerinin yakınsama hızlarının birleşik sinir ağı ve çok katmanlı perseptron sinir ağının yakınsama hızlarından daha yüksek olduğu görülmektedir. Ağ modellerinin başarımlarının karşılaştırılmasında toplam sınıflama doğrulukları ve ağların eğitimi için merkezi işlemci zamanı incelenmiştir (Tablo 5). Tablo 5’te verilen değerler dikkate alındığında, dört farklı öznitelik vektörü ile eğitilen değiştirilmiş uzman ağların karışımı modelinin, birleşik öznitelik vektörleri ile eğitilen diğer ağ modellerine göre oldukça yüksek başarımlar gösterdiği görülmektedir.

## 6. SONUÇLAR (CONCLUSIONS)

Farklı ve birleşik öznitelik vektörleri ile eğitilen dört sinir ağı modeli, üzerinde çalışılan biyomedikal işaretlerin sınıflandırılmasındaki başarımları bakımından incelenmiştir. Biyomedikal işaretlerin farklı öznitelikler ile sınıflandırma problemi olarak

ele alınmasının nedeni, biyomedikal işaretlerden öznitelik çıkarmakta kullanılan yöntemlerin farklı başarımlar göstermeleri ve en başarılı olan öznitelik vektörünün saptanmasındaki zorluktur. Bu çalışmadan çıkarılan üç önemli sonuç: (1) Farklı öznitelikler ile eğitilen değiştirilmiş uzman ağların karışımı modelinin yakınsama hızı diğer ağ modellerinin yakınsama hızlarına göre daha yüksektir; (2) Büyük boyutlu birleşik öznitelik vektörleri hesaplama karışıklığına neden olmaktadır ve birleşik öznitelikler ile eğitilen ağ modellerinin doğrulukları düşüktür; (3) Biyomedikal işaretlerin sınıflandırılmasında farklı öznitelikler ile eğitilen değiştirilmiş uzman ağların karışımı modelinin doğruluğu birleşik öznitelikler ile eğitilen ağ modellerinin doğruluklarından daha yüksektir.

## KAYNAKLAR (REFERENCES)

- West, D., West, V., “Improving diagnostic accuracy using a hierarchical neural network to model decision subtasks”, **International Journal of Medical Informatics**, Vol 57, No 1, 41-55, 2000.



2. Kwak, N., Choi, C.-H., "Input feature selection for classification problems", *IEEE Transactions on Neural Networks*, Vol 13, No 1, 143-159, 2002.
3. Übeyli, E.D., Güler, İ., "Feature extraction from Doppler ultrasound signals for automated diagnostic systems", *Computers in Biology and Medicine*, Vol 35, No 9, 735-764, 2005.
4. Chen, K., "A connectionist method for pattern classification with diverse features", *Pattern Recognition Letters*, Vol 19, No 7, 545-558, 1998.
5. Jacobs, R.A., Jordan, M.I., Nowlan, S.J., Hinton, G.E., "Adaptive mixtures of local experts", *Neural Computation*, Vol 3, No 1, 79-87, 1991.
6. Jordan, M.I., Jacobs, R.A., "Hierarchical mixture of experts and the EM algorithm", *Neural Computation*, Vol 6, No 2, 181-214, 1994.
7. Güler, İ., Übeyli, E.D., "A mixture of experts network structure for modelling Doppler ultrasound blood flow signals", *Computers in Biology and Medicine*, Vol 35, No 7, 565-582, 2005.
8. Soltani, S., "On the use of the wavelet decomposition for time series prediction", *Neurocomputing*, Vol 48, 267-277, 2002.
9. Daubechies, I., "The wavelet transform, time-frequency localization and signal analysis", *IEEE Transactions on Information Theory*, Vol 36, No 5, 961-1005, 1990.
10. Unser, M., Aldroubi, A., "A review of wavelets in biomedical applications", *Proceedings of the IEEE*, Vol 84, No 4, 626-638, 1996.
11. Lehnertz, K., "Non-linear time series analysis of intracranial EEG recordings in patients with epilepsy – an overview", *International Journal of Psychophysiology*, Vol 34, No 1, 45-52, 1999.
12. Güler, İ., Übeyli, E.D., "Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients", *Journal of Neuroscience Methods*, Vol 148, No 2, 113-121, 2005.
13. Andrzejak, R.G., Lehnertz, K., Mormann, F., Rieke, C., David, P., Elger, C.E., "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: dependence on recording region and brain state", *Physical Review E*, 64, 061907, 2001.
14. Saxena, S.C., Kumar, V., Hamde, S.T., "Feature extraction from ECG signals using wavelet transforms for disease diagnostics", *International Journal of Systems Science*, Vol 33, No 13, 1073-1085, 2002.
15. Foo, S.Y., Stuart, G., Harvey, B., Meyer-Baese, A., "Neural network-based EKG pattern recognition", *Engineering Applications of Artificial Intelligence*, Vol 15, 253-260, 2002.
16. Güler, İ., Übeyli, E.D., "ECG beat classifier designed by combined neural network model", *Pattern Recognition*, Vol 38, No 2, 199-208, 2005.
17. Goldberger, A.L., Amaral, L.A.N., Glass, L., Hausdorff, J.M., Ivanov, P.Ch., Mark, R.G., Mietus, J.E., Moody, G.B., Peng, C.K., Stanley, H.E., Physiobank, Physiokit, and Physionet: Components of a New Research Resource for Complex Physiologic Signals, *Circulation* 101(23), e215-e220 [Circulation Electronic Pages; 2000 (June 13). <http://circ.ahajournals.org/cgi/content/full/101/23/e215>];
18. Wolpert, D.H., "Stacked generalization", *Neural Networks*, Vol 5, 241-259, 1992.
19. Übeyli, E.D., Güler, İ., "Improving medical diagnostic accuracy of ultrasound Doppler signals by combining neural network models", *Computers in Biology and Medicine*, Vol 35, No 6, 533-554, 2005.