

EKG İŞARETLERİNİN FARKLI VE BİRLEŞİK ÖZNETELİKLER İLE ANALİZİ

Elif Derya ÜBEYLİ

TOBB Ekonomi ve Teknoloji Üniversitesi, Elektrik ve Elektronik Mühendisliği, 06530
Söğütözü, Ankara, e-posta: edubeyli@etu.edu.tr

ABSTRACT

In this study, the automated diagnostic systems employing diverse and composite features for 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. Because of the importance of making the right decision, classification procedures classifying the ECG signals with high accuracy were analyzed. 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.

Anahtar sözcükler: Farklı öznitelikler, Birleşik öznitelikler, EKG işareti, Otomatik tanı sistemleri

1.GİRİŞ

Tanı sistemlerinde çeşitli yöntemler kullanılmakla birlikte tanı sistemleri genellikle şu işlemlerden oluşmaktadır: ön işleme, öznitelik çıkarma/seçme ve sınıflama. Öznitelik çıkarma, şekil tanılama 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. Tanı 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, yapay sinir ağları gibi sınıflama sistemlerinin başarısını oldukça etkilemektedir [1,2].

Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabilirdiği için işlenmemiş 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 [3]. 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 özniteliği bir araya getirmek zordur, örneğin sürekli değişkenler, ikilik değerler, ayrık değişkenler, yapısal değişkenler.
- Öznitelik vektör bileşenleri genellikle bağımsız değildir.

Bu problemlerden dolayı birleşik özniteliklerin kullanımı genellikle başarımı fazla yükseltmez. Bununla birlikte, farklı öznitelikleri içeren problemlerin çözümünde birden fazla sınıflayıcının birleşimi iyi bir çözüm olabilir. Uzman ağların karışımı modelinde, geçit ve uzman ağlara aynı giriş uygulanması gerektiği için birleşik öznitelikler kullanılabilir [4]. Chen tarafından sunulan [3] değiştirilmiş uzman ağların karışımı modeli farklı özniteliklerin kullanılabilirdiği bir modeldir.

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

kayıtlardır. 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, bu düzenli dalgalardan farklı dalgaların görülmesi, dalgalar arasındaki sürelerdeki değişimler doktorlara kalp hastalığı hakkında ipuçları verirler [5,6]. Kalp yetersizliği kalbin vücut ihtiyacını karşılayabilecek kadar kan pompalayamaması durumunda oluşur. Konjestif kalp yetersizliği de denen 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 yönlere 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 [5,6]. Bu çalışmada kaynak [7]'den elde edilen, normal, konjestif kalp yetersizliği, ventriküler taşiaritmi ve atrial fibrilasyon durumlarındaki EKG işaretlerinin spektral analizi dalgacık dönüşümü ve özvektör yöntemleri ile gerçekleştirilmiş ve öznelitik vektörleri elde edilmiştir. EKG işaretlerini yüksek doğrulukla sınıflayabilmek için farklı ve birleşik öznelitikler ile eğitilen dört otomatik tanı sistemi (farklı öznelitikler ile eğitilen değiştirilmiş uzman ağların karışımı; birleşik öznelitikler ile eğitilen çok katmanlı perseptron sinir ağı, birleşik sinir ağı ve uzman ağların karışımı) incelenmiştir. Bu sinir ağlarının başarımlarının değerlendirilmesinde toplam sınıflama doğrulukları ve ağ eğitiminin merkezi işlemci zamanı ele alınmıştır.

2. DALGACIK DÖNÜŞÜMÜ VE ÖZVEKTÖR YÖNTEMLERİ

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 işlemde 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 ayrışır ve bu işlem devam eder.

Dalgacık dönüşümü aşağıda verilen şartı sağlayan alçak geçiren filtre (h) ile belirtilebilir:

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

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

$$G(z) = zH(-z^{-1}) \quad (2)$$

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

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

$$G_{i+1}(z) = G(z^{2^i})H_i(z), \quad i = 0, \dots, I-1 \quad (3)$$

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

$$\begin{aligned} h_{i+1}(k) &= [h]_{\uparrow 2^i} * h_i(k) \\ g_{i+1}(k) &= [g]_{\uparrow 2^i} * h_i(k) \end{aligned} \quad (4)$$

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:

$$\begin{aligned} \varphi_{i,l}(k) &= 2^{i/2} h_i(k - 2^i l) \\ \psi_{i,l}(k) &= 2^{i/2} g_i(k - 2^i l) \end{aligned} \quad (5)$$

burada, $2^{i/2}$ faktörü iç çarpım normalizasyonudur, i ölçeklendirme parametresi, l dönüşüm parametresidir. Ayrık dalgacık dönüşüm ayrışımı şu şekilde belirtilir:

$$\begin{aligned} a_{(i)}(l) &= x(k) * \varphi_{i,l}(k) \\ d_{(i)}(l) &= x(k) * \psi_{i,l}(k) \end{aligned} \quad (6)$$

burada, $a_{(i)}(l)$ ve $d_{(i)}(l)$ sırası ile i çözünürlüğündeki yaklaşık katsayılar ve ayrıntılı katsayılarıdır [2,6,8].

Literatürde yer alan çalışmalar incelendiğinde özvektör yöntemlerinin biyomedikal işaretlerinin spektral analizinde yüksek başarımlar gösterdiği anlaşılmaktadır [9]. Özvektör yöntemleri ile elde edilen güç yoğunluk spektrumunun logaritmik değerleri, EKG işaretlerini tanımlayan diğer farklı öznelitik vektörünü oluşturmaktadır.

Özellikle işaret gürültü oranının düşük olduğu durumlarda, özvektör yöntemleri olarak adlandırılan Pisarenko, çoklu işaret sınıflandırma (multiple signal classification - MUSIC) ve Minimum-Norm yöntemlerinin frekans çözünürlüğü oldukça yüksektir [9]. Bu yöntemler ile EKG işaretlerinin güç yoğunluk spektrumlarının elde edilmesinde kullanılan ifadeler denklem (7)-(9)'da verilmektedir.

$$P_{PISARENKO}(f) = \frac{1}{|A(f)|^2} \quad (7)$$

$$\text{burada } A(f) = \sum_{k=0}^m a_k e^{-j2\pi f k}, \text{ dir.}$$

Yanıtıcı tepeler oluşturmasından dolayı Pisarenko yöntemi, EKG işaretlerinin spektral analizi için uygun bulunmamıştır.

$$P_{MUSIC}(f) = \frac{1}{\frac{1}{K} \sum_{i=0}^{K-1} |A_i(f)|^2} \quad (8)$$

$$P_{MIN}(f, K) = \frac{1}{|A(f)|^2} \quad (9)$$

MUSIC ve Minimum-Norm yöntemleri ile elde edilen EKG güç yoğunluk spektrumlarının birbirine yakın olduğu görülmüştür.

3. FARKLI ÖZİNTELİK VEKTÖRLERİNİN HESAPLANMASI

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. EKG işaretlerinin ayrışım seviyelerinin sayısı 4 olarak tespit edilmiştir. Bu durumda, EKG işaretleri $D_1 - D_4$ ayrıntılı alt bandlarına ve son olarak A_4 yaklaşık alt bandına ayrılmıştır. EKG işaretlerinin

dalgacık katsayılarının hesaplanmasında 2. dereceden Daubechies dalgacık (db2) kullanımının uygun olduğu belirlenmiştir. Her bir EKG bölütü için 265 dalgacık katsayısı elde edilmiştir. Çıkarılan öznelik vektörlerinin boyutlarının azaltılabilmesi için özvektör yöntemleri ile elde edilen güç yoğunluk spektrumunun logaritmik değerleri ve dalgacık katsayıları üzerinde aşağıda belirtilen istatistiksel özellikler kullanılmıştır:

1. Özvektör yöntemleri ile elde edilen güç yoğunluk spektrumlarının logaritmik değerlerinin enbüyükleri, her bir alt banddaki dalgacık katsayılarının mutlak değerlerinin enbüyüğü.
2. Özvektör yöntemleri ile elde edilen güç yoğunluk spektrumlarının logaritmik değerlerinin ortalamaları, her bir alt banddaki dalgacık katsayılarının mutlak değerlerinin ortalaması.
3. Özvektör yöntemleri ile elde edilen güç yoğunluk spektrumlarının logaritmik değerlerinin enküçükleri, her bir alt banddaki dalgacık katsayılarının mutlak değerlerinin enküçüğü.
4. Özvektör yöntemleri ile elde edilen güç yoğunluk spektrumlarının logaritmik değerlerinin standard sapmaları, her bir alt banddaki dalgacık katsayılarının mutlak değerlerinin standard sapması.

EKG işaretlerinin farklı sınıflarına ait örnek işaretleri için hesaplanan öznelikleri Tablo 1 ve 2'de verilmektedir. Farklı öznelik vektörlerinin hesaplanmasında MATLAB program paketi kullanılmıştır.

Tablo 1: Dört farklı sınıfa ait EKG işaretlerinden özvektör yöntemleri ile hesaplanan öznelikler

EKG işaretleri	Öznelikler	Pisarenko	MUSIC	Minimum-Norm
Normal	Enbüyük	-8.3262	-6.1429	-5.9119
	Ortalama	-29.0350	-25.5815	-24.9883
	Enküçük	-63.3942	-48.5747	-45.7063
	Standard sapma	15.5270	14.6241	13.9427
Konjestif kalp yetersizliği	Enbüyük	15.4373	14.8120	11.8117
	Ortalama	-34.2724	-33.0135	-32.4818
	Enküçük	-58.5668	-54.1374	-52.5681
	Standard sapma	21.1599	19.0780	18.4921
Ventriküler taşiaritmi	Enbüyük	8.9680	6.5634	5.3926
	Ortalama	-44.5406	-43.3792	-42.9259
	Enküçük	-73.2121	-66.8833	-65.4340
	Standard sapma	28.8429	25.2899	24.1945
Atrial fibrilasyon	Enbüyük	19.4951	23.0237	22.6390
	Ortalama	-39.9064	-36.4000	-36.0503
	Enküçük	-62.0746	-54.3199	-52.6743
	Standard sapma	21.4749	19.9989	19.1709

Tablo 2. Dört farklı sınıfa ait EKG işaretlerinden hesaplanan dalgacık katsayıları

EKG işaretleri	Öznitelikler	Dalgacık katsayıları				
		Alt bandlar				
		D ₁	D ₂	D ₃	D ₄	A ₄
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

4. OTOMATİK TANI SİSTEMLERİNİN EKG İŞARETLERİNE UYGULANMASI

Otomatik tanı sistemlerinde kullanılan eğitim ve test verileri 32 boyutlu (öznitelik vektörünün boyutu) 720 vektörden oluşmaktadır (her bir sınıftan 180 vektör). Bu vektörlerden 360'ı (her bir sınıftan 90 vektör) ağların eğitimi için 360'ı (her bir sınıftan 90 vektör) ağların testi için kullanılmıştır. Değiştirilmiş uzman ağların karışımı modelinde 12 uzman ağ kullanılmış ve uzman ağlar dört farklı öznitelik vektörünün uygulandığı dört gruba bölünmüştür (her grupta 3 uzman ağ yer almaktadır). Aynı sınıflama problemi için 4 uzman ağdan oluşan ve birleşik öznitelik vektörleri (32 giriş) ile eğitilen uzman ağların karışımı modeli geliştirilmiştir. Bu çalışmada, geçit ve uzman ağlar çok katmanlı perseptron sinir ağlarından oluşturulmuştur. Gerçekleştirilen birleşik sinir ağı modelinde EKG işaretlerinin 4 farklı sınıfı olduğu için ilk seviyede 4 sinir ağı eğitilmiştir. Her bir ağ bir tip sınıflamayı diğerlerine göre daha doğru yapacak şekilde eğitilmektedir. Ağın mimarisinde tek gizli katmanı olan çok katmanlı perseptron sinir ağları yer almaktadır. Her bir ağın girişi 32 nörondan (birleşik öznitelik vektör boyutu) oluşmaktadır. Gizli nöron sayısı 30, çıkış sayısı 4'tür. Ağların çıkış vektörleri (0,0,0,1), (0,0,1,0), (0,1,0,0), (1,0,0,0) şeklindedir. Birinci seviyedeki ağ çıkışlarını birleştiren ikinci seviyedeki sinir ağları eğitilmiştir. İkinci seviyedeki ağların girişi 16 nörondan (birinci seviyedeki ağların çıkışları) oluşmaktadır. Gizli nöron sayısı 30 ve istenen çıkışlar birinci seviyedeki ağların çıkışları ile aynıdır. Farklı sınıflayıcıların başarımlarını karşılaştırmak amacı ile aynı sınıflama problemi için birleşik öznitelik vektörleri ile eğitilen çok katmanlı perseptron sinir ağı geliştirilmiştir.

Geliştirilmiş olan ağ modellerinin eğitim ardışıklarının sayısı ve ağ parametreleri Tablo 3'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 4). Tablo 4'te verilen değerler incelendiğinde 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.

5. SONUÇLAR

Farklı ve birleşik öznitelik vektörleri ile eğitilen dört sinir ağı modeli, EKG işaretlerinin sınıflandırılmasındaki başarımları bakımından incelenmiştir. EKG işaretlerinin farklı öznitelikler ile sınıflandırma problemi olarak ele alınmasının nedeni, EKG işaretlerinden 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) EKG işaretlerinin sınıflandırılmasında farklı öznitelikler ile eğitilen değiştirilmiş uzman ağların karışımı modelinin doğruluğu birleşik öznitelikler ile eğitilen ağ modellerinin doğruluklarından daha yüksektir.

Tablo 3: Sınıflayıcıların ağ parametreleri

Sınıflayıcı (öznitelik)	Ağ parametreleri
Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	$8 \cdot 25 \cdot 4^a$, $8 \cdot 25 \cdot 4^a$, $8 \cdot 25 \cdot 4^a$, $8 \cdot 25 \cdot 4^a$, $8 \cdot 25 \cdot 4^b$, $8 \cdot 25 \cdot 4^b$, $8 \cdot 25 \cdot 4^b$, $8 \cdot 25 \cdot 4^b$, 600^c
Uzman ağların karışımı (birleşik öznitelikler)	$32 \cdot 25 \cdot 4^a$, $32 \cdot 25 \cdot 4^d$, 800^c
Birleşik sinir ağı (birleşik öznitelikler)	$32 \cdot 30 \cdot 16^e$, $16 \cdot 30 \cdot 4^f$, 1700^c
Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	$32 \cdot 25 \cdot 4^g$, 2500^c

^aUzman ağların tasarımı: Giriş · gizli · çıkış nöronları

^bGeçit ağlarının tasarımı: Giriş · gizli · çıkış nöronları

^cEğitim ardışımının sayısı

^dGeçit ağının tasarımı: Giriş · gizli · çıkış nöronları

^eBirinci seviyedeki ağ tasarımı: Giriş · gizli · çıkış nöronları

^fİkinci seviyedeki ağ tasarımı: Giriş · gizli · çıkış nöronları

^gSinir ağı tasarımı: Giriş · gizli · çıkış nöronları

Tablo 4: Toplam sınıflama doğrulukları ve eğitim için merkezi işlemci zamanı

Sınıflayıcı (öznitelikler)	Toplam sınıflama doğruluğu (%)	Merkezi işlemci zamanı (dak:s)
Değiştirilmiş uzman ağların karışımı (farklı öznitelikler)	97.78	8:43
Uzman ağların karışımı (birleşik öznitelikler)	96.11	10:17
Birleşik sinir ağı (birleşik öznitelikler)	95.28	14:25
Çok katmanlı perseptron sinir ağı (birleşik öznitelikler)	91.67	15:24

KAYNAKLAR

- [1] Kwak, N., Choi, C.-H., "Input feature selection for classification problems," *IEEE Transactions on Neural Networks*, Vol. 13, No. 1, pp. 143-159, 2002.
- [2] Übeyli, E.D., Güler, İ., "Feature extraction from Doppler ultrasound signals for automated diagnostic systems," *Computers in Biology and Medicine*, Vol. 35, No. 9, pp. 735-764, 2005.
- [3] Chen, K., "A connectionist method for pattern classification with diverse features," *Pattern Recognition Letters*, Vol. 19, No. 7, pp. 545-558, 1998.
- [4] 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, pp. 565-582, 2005.
- [5] S.C. Saxena, V. Kumar, S.T. Hamde, "Feature extraction from ECG signals using wavelet transforms for disease diagnostics," *International Journal of Systems Science*, Vol. 33, No. 13, pp. 1073-1085, 2002.
- [6] Güler, İ., Übeyli, E.D., "ECG beat classifier designed by combined neural network model," *Pattern Recognition*, vol. 38, No. 2, pp. 199-208, 2005.
- [7] A.L. Goldberger, L.A.N. Amaral, L. Glass, J.M. Hausdorff, P.Ch. Ivanov, R.G. Mark, J.E. Mietus, G.B. Moody, C.K. Peng, H.E. Stanley, 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>];
- [8] I. Daubechies, "The wavelet transform, time-frequency localization and signal analysis," *IEEE Transactions on Information Theory*, Vol. 36, No. 5, pp. 961-1005, 1990.
- [9] Übeyli, E.D., Güler, İ., "Comparison of eigenvector methods with classical and model-based methods in analysis of internal carotid arterial Doppler signals," *Computers in Biology and Medicine*, Vol. 33, No. 6, pp. 473-493, 2003.