

T.C.
DİCLE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü

BEYİN SİNYALLERİNİN MODERN SPEKTRAL ANALİZ YÖNTEMLERİ İLE KESTİRİMİ

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

Muhammet Ali ARSERİM

106516

YÜKSEK LİSANS TEZİ

(ELEKTRİK ELEKTRONİK ANABİLİM DALI)

106516

DİYARBAKIR
HAZİRAN - 2001

T.C.
DICLE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü'ne
DIYARBAKIR

Bu çalışma jürimiz tarafındanElektrik-Elektronik Mühendisliği.....
Ana Bilim Dalı'nda YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyesinin Ünvanı, Adı Soyadı


Başkan : Prof. Dr. İnan GÜLER inanciler

Üye : Doç. Dr. Sabir RÜSTEMOV Sabir

Üye : Yrd. Doç. Dr. Mehmet AKIN Mehmet

Yukarıdaki bilgilerin doğruluğunu onaylarım

08 / 06 / 2001


Prof. Dr. H. İnan
Enstitü Müdürü

TEŞEKKÜR

Bu çalışmam sırasında yakın desteğini gördüğüm danışman hocam Yrd. Doç. Dr. Mehmet AKIN'a teşekkürlerimi sunarım.

Buna ilaveten Her türlü maddi ve manevi desteklerine benden esirgemeyen aileme, özellikle babam Suphi Tayyar ARSERİM'e, annem Ayşe ARSERİM'e ve ablam Neval Berrin ARSERİM'e sonsuz şükranlarımı sunarım.

Ayrıca bilimsel desteklerini esirgemeyen meslektaşlarım sayın Bilal GÜMÜŞ ve İbrahim TÜRKOĞLU'na ve bana bu çalışmamı bitirmemde destek olan mesai arkadaşlarım özellikle Yrd. Doç. Dr. F. Demet ÇETİN, M. Selçuk KESKİN ve Sedat BİNGÖL'e sonsuz şükranlarımı sunarım.



AMAÇ

Günümüzde, epilepsi önemli beyin rahatsızlıklarından biri olarak ciddiyetini korumaktadır. Özellikle epileptik deşarjların meydana gelmesi esnasında kaydedilen elektroensefalogramın içerdiği dalga şekilleri diğer bazı beyin rahatsızlıklarındaki dalga şekilleriyle benzerlik göstermesinden dolayı epilepsi hastalığı kolay tespit edilememektedir. Bu yüzden de teşhisi yapacak doktorun deneyiminin fazla olması gerekmektedir.

Son zamanlarda işaret işleme tekniklerinin gelişimi ve bu alanda kullanılan yazılım programlarının desteklediği cihazların yüksek performanslarından dolayı, hastalıkların teşhisinde işaret işleme etkin olarak kullanılmaktadır.

Yapılan bu çalışmada beyin işaretleri önce önemli alt frekans bileşenlerine(δ , θ , α ve β) ayrılmıştır. Bu ayırma işlemini sağlamak için dalgacık dönüşümü yöntemi kullanılmıştır. Dalgacık dönüşümünün bir diğer avantajı da işaretlerin alt bileşenlerinin zaman boyutunda görüntülenmesidir. Daha sonra teşhisi koyacak kişilerin doktorlar olduğu düşünülürse, yorumlamada yardımcı olabilmesi için yapay sinir ağı modellemeleri kullanılmıştır. Yapay sinir ağının en önemli özelliği öğrendikten sonra karar verme yetisine sahip olmasıdır.

Bu çalışmanın amacı da epilepsi teşhisinde, modern işaret işleme teknikleri kullanarak doktorlara teşhis koymaları bakımından yardımcı olmak ve deneyimle birlikte gözleme bağlı olacak hataları minimuma indirmektir.

ÖZET

Beyinde üretilen elektriksel aktivitelerin kaydedilen grafiğine elektroensefalografi(EEG) denmektedir. EEG, özellikle beynin fonksiyonel ve mental aktivitesi incelenirken faydalı olmaktadır. EEG işaretleri, beynin fiziksel ve zihinsel aktivitesine göre dört ana frekans bandına sahip spektral bileşenler(δ , θ , α ve β dalgaları) içermektedir.

EEG işaretlerinin bilgisayar ortamında incelenmesi için öncelikle işaretlerin sayısal hale getirilmesi, daha sonra da kaydedilmesi gerekmektedir. Bunun için bilgisayarla EEG cihazı arasında bir ara birim ünitesi kullanılmıştır.

Sayısallaştırılıp kaydedilen EEG işaretleri modern işaret işleme tekniklerinden biri olan dalgacık dönüşümü yöntemi ile spektral bileşenlerine ayrılmıştır. Dalgacık dönüşümü yöntemi, işareti zaman ve frekans boyutunda incelemektedir. Böylece işaretlerin spektral bileşenlerinin zaman boyutunda aldığı değerleri de görmekteyiz.

Bu çalışmada elde edilen EEG spektral bileşenleri bir yapay sinir ağı modelinin girişlerine uygulanmış ve yapay sinir ağı bu girişlere bağlı olarak eğitilmiştir. Buna göre yapay sinir ağının çıkışları giriş işaretine göre çıkışta insan beynine ait bazı parametreleri ortaya koymaktadır.

Sonuç olarak gelişen teknolojinin yanı sıra işaret işleme tekniklerinin etkin kullanımı hastalık teşhislerinde faydalı olabilecek yenilikleri ve yapılabilecek hataları minimuma indirme olanağını beraberinde getirecektir.

SUMMARY

The recorded representation of the electrical activities that are produced in the brain is called electroencephalography (EEG). EEG, may be useful, especially when investigation of the functional, and the mental activities of the brain are considered. EEG signals include spectral components(δ , θ , α , β waves) that have four major frequency bandwidths with respect to the functional, and the mental activities of the brain.

To analyze the EEG signals using computers, they must be suited digitization, and than recorded. To do this, an interface unit is used between the computer, and the Electroencephalograph

The digitized, and recorded EEG signals have been distinguished into their spectral components by using Wavelet transform method which is the one of the modern signal processing technique. Wavelet transform method investigated the signal both in time and the frequency domains. So we can easily see the values of the spectral components of the signal in the time domain.

In this study, the obtained spectral components of the EEG signals are applied to the inputs of artificial neural network model, and this model is trained according to these inputs. So, the outputs of the artificial neural network will show the health conditions of the patients.

As a result, besides the developing technology, using signal processing techniques effectively brings the improvements that are useful in the illness' diagnosing and the opportunity of the reducing the errors that are made in the diagnosing of the illness with it.

İÇİNDEKİLER

TEŞEKKÜR	i
AMAÇ	ii
ÖZET	iii
SUMMARY	iv
İÇİNDEKİLER	v
1. GİRİŞ.....	1
2. ÖNCEKİ ÇALIŞMALAR	3
3. MATERYAL VE METOT	6
3.1. İnsan Beyninin Sahip Olduğu Spektral Bileşenler	6
3.1.1. Normal Beyin Dalgaları.....	6
3.1.1.1. Alfa Dalgaları	6
3.1.1.2. Beta Dalgaları	6
3.1.2 Anormal Beyin Dalgaları.....	7
3.1.2.1. Sporadik Dalgalar	7
3.1.2.2. Kompleks Dalgalar	8
3.2. Epilepsi	9
3.3 Gerçekleştirilen Sistemin Donanımı.....	10
3.4. Wavelet(Dalgacık) Dönüşümü	11
3.4.1. Sürekli Dalgacık Dönüşümü.....	14
3.4.1.1. Ağırlıklandırma	15
3.4.1.2. Kaydırma	15
3.4.1.3. İşaretlere Sürekli Dalgacık Fonksiyonunun Uygulanması.....	15
3.4.2. Ayrık Dalgacık Dönüşümü	17
3.4.2.1. Seviye Sayısı.....	19
3.4.2.2. İşaretin Rekonstrüksiyonu	20
3.4.2.3. Paket Analizleri	20
3.5. Yapay Sinir Ağları.....	21
3.5.1. Biyolojik Nöron.....	22
3.5.2. Yapay Nöron Modeli	24
3.5.3. Yapay Sinir Ağlarının Yapısı	28
3.5.3.1. Ağ Yapıları	30
3.5.3.2. Yapay Sinir Ağlarının Eğitilmesi	31

3.5.4. Perseptron ve Eğitim Algoritması	31
3.5.4.1. Perseptron Eğitim Algoritması	33
3.5.5. Çok Katmanlı Yapay Sinir Ağının Geri-Yayılım Algoritması İle Eğitilmesi	36
3.5.5.1. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı İçin Geri Yayılım Öğrenme Algoritması	37
4. BULGULAR.....	40
4.1. EEG Veri Setleri.....	40
4.2. EEG Veri Setlerine Dalgacık Dönüşümünün Uygulanması	44
4.3. Dalgacık Dönüşümü Sonrası Elde Edilen Verilerin Yapay Sinir Ağına Uygulanması ..	56
4.3.1. Uygulama Sonuçları	56
4.3.2. Yapısı.....	56
4.3.3. Oluşturulacak Yapay Sinir Ağı İçin Gerekli Program.....	57
5. SONUÇLAR VE TARTIŞMA.....	66
6. KAYNAKLAR.....	68
ŞEKİLLER TABLOSU	71
YAZARIN ÖZGEÇMİŞİ.....	72

1. GİRİŞ

İnsan beyni yapısı ve fonksiyonları itibariyle vücudun en karmaşık organlarından biridir. Bu nedenle beyinde meydana gelen biyoelektriksel aktiviteler, bunların yapısal özellikleri, beyinde meydana gelen tahribatlar, beyin hastalıkları, düşünmenin beyinde nasıl meydana geldiği ve beyinin haritalanması gibi konular günümüzde bilimsel çalışmaların üzerinde en çok yoğunlaştığı konulardandır.

Halk dilinde sara hastalığı olarak bilinen epilepsi, beyinde meydana gelen önemli rahatsızlıklardan biridir. Epilepsi hastalarında, epileptik deşarjların meydana geldiği anlarda hasta kendi hareketlerini kontrol edememektedir.

Günümüzde beyin yapısal ve fonksiyonel rahatsızlıklarını tespit etmek için çok çeşitli cihazlar kullanılmaktadır. Bu cihazlardan birkaçı Manyetik Rezonans(MR), Beyin Tomografisi(BT) ve Elektroansefalografidir(EEG). Her ne kadar MR ve BT cihazlarının bulunmasından sonra EEG'nin önemi azalmış olarak görünse de beyinin fonksiyonel rahatsızlıklarını ve özellikle epilepsi hastalığının teşhisinde EEG cihazı nöroloji kliniklerinde rutin olarak kullanılmaktadır[1]. Buna ilaveten son yıllardaki teknolojik gelişmeler sayesinde uzun süreli video/EEG görüntülemesi ile hastalık nöbetine ait kayıtlar elde edilerek epilepsinin daha güvenilir sınıflandırılması yapılarak, epileptik odağın beyinin hangi kesiminden kaynaklandığı belirlenebilmektedir[2]. Fakat ülkemizin gelişmiş bölgelerindeki hastaneler hariç, diğer hastanelerde bu tip modern teknikler olanakların azlığı nedeniyle kullanılamamaktadır. Dolayısı ile epilepsi gibi hastalıkların teşhisi doktorların deneyimleri ve bilgilerine bağlı olarak yapılmaktadır. Buna ilaveten doktorların yapacakları en ufak hatanın çok büyük tahribatlara yol açacağını göz önünde bulundurursak, doktorların bu hatalarını önlemede kendilerine fayda sağlayacak modern gelişmeleri hayata geçirmek gerekmektedir.

Günümüzde işaret işleme teknikleri, modern bilgisayarların ve yeni tekniklerin kullanılmasıyla birlikte günümüzde bir çok bilimsel disiplinde etkin olarak kullanılmaktadır. Bu bilimsel disiplinlerin en önemlilerinden birisi de kuşkusuz insan sağlığının hayatımızdaki öneminden dolayı tıp bilimidir. Bu yüzden yüzyıllar boyu bilim adamları tıp bilimiyle uğraşmışlardır. Kuşkusuz, işaret işleme tekniklerinin tıpta kullanımı hastalıkların teşhis ve tedavisinde çok farklı bir bakış açısı sağlamıştır.

Modern işaret işleme tekniklerinden olan yapay sinir ağı modellemesi ve dalgacık dönüşümü son yıllarda yapıları itibariyle ilgi konusu olmuştur ve bir çok alanda kullanılan metotların yerini almıştır. EEG işaretlerinin yapısı itibariyle durağan olmadıklarından dolayı bu işaretlerin analizinde dalgacık dönüşümünün kullanılması bu konuyla uğraşan insanlar için çok cazip gelmektedir. Ayrıca yapay sinir ağı modellemeleri çözümü çok zor olan problemler için basit sonuçlar üretmektedir[3].

Yukarda anlatılanların ışığında, EEG işaretlerinin hem zaman-frekans hem de genlik özelliklerini analiz etmek için dalgacık dönüşümü ve yapay sinir ağı modellemesinin kullanılması faydalı olacaktır. Böylece EEG'ye ait frekans ve zaman özelliklerinin çıkarılmasıyla birlikte bu özelliklere bağlı basit sonuçlar üretmek doktorlar için teşhis koymada büyük kolaylıklar sağlayacaktır.

Şimdiye kadar anlatılanlar sinyal işleme tekniklerinin hastalık teşhisinde önemli rol oynadığını göstermektedir. Bu bağlamda bu çalışmada kullanılacak olan dalgacık dönüşümü ve yapay sinir ağları ile hastalık teşhisinde daha ileri noktalara ulaşılacağı öngörülmektedir.

Bütün bunların sonucunda, işaret işleme metotları hastalık teşhis ve tedavisinde büyük rol oynadığını söyleyebilmekteyiz. Bununla birlikte modern işaret işleme metotlarından olan dalgacık dönüşümü yöntemi ve yapay sinir ağı modellemesinin bu konuda büyük bir çıkar açacağı görülmektedir.

2. ÖNCEKİ ÇALIŞMALAR

Beyinde üretilen elektrik potansiyellerinin kaydedilen grafiğine elektroansefalografi (EEG) denmektedir. Bu alanda yapılan ilk çalışmalar, bir İngiliz fizyoloğu olan CATON'a dayanmaktadır[4].

CATON 1875 yılında, beynin dış yüzeyindeki iki nokta veya biri boz nesne diğeri de kafatasının yüzeyi olmak üzere konulan iki elektrottan yönü değişen zayıf akımların geçtiğini bildirmiştir. CATON, kedi, maymun ve tavşanların beyin elektriksel aktiviteleri üzerinde, optik büyültmeli bir galvanometreye kutupsuz kortikal elektrotlar bağlayarak araştırmalarını sürdürmüştür. Bunu izleyen yıllarda, çeşitli çalışmacılar, bazıları CATON'un Araştırmalarını bilmiyordu, hayvanların EEG'lerini incelediler ve spontan aktivite dışardan uyarıma karşı uyarılmış cevapların değiştiğini gösterdiler. 1876 Karkov'da, DANILEVSKEY akustik uyarıma karşı korteksteki duran potansiyelde bir değişimin olduğunu göstermiştir. 1930'lu yıllarda alternatif akım(a.c) kuplajlı lambalı yükselteçlerin gelişmesi, daha önceden çok başarılı bir şekilde çalışılmış olunan sürekli potansiyellerin değişimi üzerinde yapılacak ileriki çalışmalara şüphesiz olarak büyük bir katkı sağlamıştır. CYBULSKİ 1914 yılında, bir köpekte kortikal uyarımın neden olduğu bir epileptik deşarj kaydetmiştir. KAUFFMAN 1910 yılında benzer çalışmaları yapmış ve epileptik deşarj esnasında elektrot bağlantısının sağlanamamasından şikayet etmişti. Bütün bu ilk çalışmalar hayvanlar üzerinde yapıyordu ve 1920'li yılların başına kadar böyle devam etti. Bu dönemde Avusturyalı Dr. HANS BERGER kafatasında boşluklara sahip olan insanlar üzerinde araştırmalar yapmaya başladı ve kayıtlarını da bir film kağıdı üzerine dalgalı ışık spotu yardımıyla kaydetti ve alfa adını verdiği saniyede yaklaşık olarak 10 kez tekrarlanan düzenli dalgaları buldu. HANS BERGER 1929 yılında insan EEG'si üzerinde yapılan ilk çalışmalarını kağıda döktüğü zaman alfa dalgalarından daha hızlı fakat daha düşük genliğe sahip olan beta dalgalarından bahsetmiştir[4].

1940'lı yıllardan bu yana EEG kayıt tekniğinde çok fazla bir değişim meydana gelmemiştir. Bu yönde en büyük çaba güvenilir çok kanallı kaydedicilerin tasarlanması üzerine olmuştur. 1950'li yıllarda transistor kıyıcı yükselteçlerin kullanılmasıyla doğru akım(d.c.) kaydına dönüş başarılmıştır. Fakat elektrotlar hala montaj zorluğundan dolayı problem olmaya devam etmektedir.

EEG'nin spektrum analizi ile ilgili uygun metot bulmak için bu konuyla ilgili olarak bir çok çalışma yapılmıştır. COHN dahili interpolalara göre darbelerin sayısını elde etmek için aynı seviyede geçen darbelerin karşılaştırılması tekniğini kullanarak bir histogram oluşturmuştur. LEADER, dalga şekillerinin orta noktasını bulma tekniğini kullanmış ve taban hattın değişiminin sebep olduğu hataları düzeltmeyi amaçlamıştır[5].

EEG'nin frekans analizi ile ilgili uygun metot bulmak için çok çeşitli çalışmalar yapılmıştır. Bu çalışmalardan ilki COHN tarafından yapılmıştır. COHN dahili interpolalara göre darbelerin sayısını elde etmek için aynı seviyede geçen darbelerin karşılaştırılması tekniğini kullanarak bir histogram oluşturmuştur[5].

Periyot analiz yöntemi, CARRIE ve FROST gibi, DASCALOV ve CHAVDAROV, PALEM ve BARR tarafından EEG dalgalarının hem periyodu hem de genliği hesaba katılarak iyileştirilmiştir[5].

McCULLOCH ve PİTTS 1943 yılında ilk yapay nöron fikrini ortaya attılar. HEBB 1949 yılında nöron bağlantılarını modifike etmek için bir öğrenme kuralı geliştirdi. WİDROW ve HOFF 1960'lı yılların başında kendi adlarıyla anılan Widrow-Hoff öğrenme kuralını geliştirdiler. Daha sonra KOHONEN(1977, 1978, 1984, 1988) ve ANDERSON(1977) ilişkili hafıza araştırmalarını geliştirdiler. Daha sonraları GOSBERG(1982), HOPFIELD(1984) gibi bir çok bilim adamı yapay sinir ağı modellemesi gelişimi üzerine çalışmalar yürüttüler.[3]

Dalgacık teriminin ilk kez duyulması ALFRED HAAR tarafından 1909 yılında bir tezde olmuştur. Dalgacık kavramının ilk kez kendi teorik formunda bahsedilmesi JEAN MORLET ve Fransa 'da Marsilya teorik fizik merkezinde ALEX GROSSMANN'ın idaresinde çalışan bir takım tarafından yapılmıştır. Genel bir şekilde dalgacık analizi metotları, metotların yayılmasını sağlayan Y. MEYER ve arkadaşları tarafından geliştirilmiştir. Fakat ana algoritma 1988deki STEFAN MALLAT'ın çalışmalarına kadar uzanmıştır. Bundan sonra dalgacıklar üzerindeki çalışmalar enternasyonal hale geldi. Bu araştırmalar INGRID DAUBECHIES, RONALD COIFMAN, ve VICTOR WICKERHAUSER gibi bilim adamlarının çalışmalarıyla öncülük edildiği A.B.D.'de özellikle aktif bir haldedir[6].

EEG'nin spektral analizi hususunda günümüze kadar bir çok çalışma yapılmıştır. Bu alanda uygulanan klasik metotlarla birlikte son yıllarda dalgacık dönüşümü, yapay sinir ağı modellemesi ve bulanık mantık gibi modern işaret işleme teknikleri de sıkça kullanılmaya başlanmıştır[7],[8],[9],[10],[11].

SHİMADA ve arkadaşları uyku EEG'sinin karakteristik özelliklerini yapay sinir ağı kullanarak incelemişlerdir[7].

HAZARİKA ve çalışma grubu 1995 yılında dalgacık dönüşümü ve yapay sinir ağı kullanarak şizofreniyi sınıflandırmıştır[8].

MEHTA ve çalışma grubu dalgacık dönüşümü yöntemi ile epileptik deşarjları incelemiştir[9].

REUTER epileptik olayları yapay sinir ağı kullanarak incelemiştir[10].

GEVA ve KEREM epileptik deşarjları dalgacık dönüşümü ve bulanık mantık kullanarak incelemişlerdir[11].



3. MATERYAL VE METOT

3.1. İnsan Beyninin Sahip Olduğu Spektral Bileşenler

Beyinde, insanın fizyolojik, psikolojik ve sağlık durumlarına göre farklı frekans ve genlikte çeşitli dalgalar meydana gelmektedir. İnsana sağlıklı veya hasta teşhisinin konulabilmesi için EEG kaydının hangi koşullarda yapıldığı göz önüne alınıp, bu kayıttan alınan EEG sinyalin frekans ve genlik analizi yapılmalıdır.

3.1.1. Normal Beyin Dalgaları

Sağlıklı bir insanda beyinde üretilen normal dalgalar alfa ve beta dalgaları olarak adlandırılmaktadır. Günlük hayatta, insanların uyanık ve herhangi bir aktiviteleri olması durumunda beta dalgalarını ürettiği gözlenmiştir. İnsanlar gözlerini kapatıp dinlenme konumuna geçtikleri zaman alfa dalgaları belirlemeye başlar.

3.1.1.1. Alfa Dalgaları

Görünümü itibari ile sinüzoidal ve monoritmik olan bu dalgalar genellikle 8-12 Hz frekans bandına ve 40-50 mikrovolt arasındaki genliklere sahiptirler. Alfa dalgaları genellikle insanın gözlerini kapatıp dinlenmeye başlaması ile ortaya çıkmaktadır. Bu yüzden alfa dalgasına beyin boş veya doğal frekansı da denmektedir. Bu dalgalar ilkin BERGER tarafından ortaya konmuş ve beyin bioelektrik aktivitesinin tek göstergesi olarak kabul edilmiştir. Sonraları ADRIAN ve MATHEWS ve yine ADRIAN ve YAMAGIWA bu konuda geniş araştırmalar yapmış ve sonunda ortaya koydukları bilgiler çok fazla değişikliğe uğramadan günümüze kadar gelmiştir. Alfa dalgaları genellikle beyinin daha çok arka yarısında ve Parieto-occipital bölgede hakimdir. Seyrek olarak da alfa dalgaları beyin temporal, central hatta frontal alanlarında da gözlenmektedir[12].

3.1.1.2. Beta Dalgaları

Beta dalgaları genellikle insanların gözleri açık iken ve herhangi bir aktiviteleri varsa ortaya çıktığı düşünülmektedir. Beta dalgaları genellikle desenkronize dalgalardır. Beta dalgaları yüksek frekanslı düşük genlikli dalgalardır. Genellikle beta dalgalarının frekansının 12 Hz'den yukarı ve genliklerinin ise 10-20 mikrovolt olduğu düşünülmektedir. Beta dalgaları genellikle Fronto-central bölgelerde görülür. Alfa dalgalarının uyarım sonucu bloke

olmasından dolayı o bölgede görülen aktivite beta dalgalarıdır. BERGER, alfa frekansı dışında görülen bütün aktiviteye beta dalgaları demişse de bu doğru değildir[12].

Buna ilaveten insanların uyku esnasında rüya görmeye başladıkları anda beynin yüksek aktivite gösterdiği gözlenmiştir. Bu döneme REM (Rapid Eye Movement-Hızlı Göz Hareketi) denmektedir. Fakat her ne kadar beyin yüksek aktivite göstermekteyse de vücut kasları hareket göstermemektedir[13].

3.1.2 Anormal Beyin Dalgaları

Uyanık insanlardan kaydedilen EEG traselerinde, alfa dalgasından daha düşük frekanslı delta ve teta dalgalarının dominant olarak görülmesi bu bireylerin beyinlerinde bir rahatsızlık olduğunu akla getirmektedir. Yani yetişkin bireylerde, uyku dönemleri haricinde düşük frekanslı delta ve teta dalgalarının etkinliği patolojik veya çeşitli beyin rahatsızlıkları esnasında görülmektedir. EEG kaydıyla görülen anomalilerden bazıları epilepsi ve şizofrenidir. Beyindeki patolojik dalgalar sporadik veya kompleks halinde ortaya çıkmaktadırlar. Anormal beyin dalgaları morfoloji bakımından ister sporadik ister kompleks biçiminde olsun, anormal dalgalar morfoloji bakımından durgunluk dönemindeki normal dalgalardan farklı oldukları kadar, meydana çıktıkları bölgenin temel aktivitesinden daha fazla genlik değerlerine sahiptirler[14].

Anormal dalgaların frekans analizi yapıldığı zaman bu dalgaların genelde çalışmamızda da uygulanan delta ve teta frekans bandı aralıkları içerisinde olduğu ortaya çıkmaktadır.

3.1.2.1. Sporadik Dalgalar

Sporadik dalgalar arızı, izole veya belirli frekanslar tarzında ritmik olarak ortaya çıkmaktadırlar. Çoğu kere hemisferin bir bölgesinde lokalize olmakla birlikte, bazen her iki hemisferin benzer bölgelerinde senkron bir tarzda da görülebilirler[14].

Sporadik dalgalar, diken(spike), keskin(sharp) ve yavaş(slow) dalgalar olmak üzere sınıflandırılabilirler[14].

Diken dalga bir defleksiyon olarak ortaya çıkmaktadır ve frekansı büyüktür. Başlangıcı ile bitimi arasındaki süre 20-60 ms kadardır. Diken dalga korteksin yüzeyinden çıkar ya da alt

kortikal bölgede görülür. Diken dalga belirgin ise yüksek genliğe sahip olur. Korteks yüzeyinde daha alt bölgeden elde edilen diken dalgalar düşük genliklidirler[14].

Keskin dalgalar tek fazlı ya da üç fazlı olabilmektedirler. Bir keskin dalga 60-150 ms süresince vardır. 150-300 ms süreli keskin çıkış, yavaş inişli bu tip dalgalara da keskin-yavaş(sharp-slow) dalgalar denmektedir[14].

Frekans bileşenleri 8 Hz'in altındaki dalgalar yavaş dalgalar denmektedir. WALTER adındaki bir araştırmacı yavaş dalgaları ikiye ayırmıştır. Bu dalgalardan 4-7 Hz frekansa sahip olanlara teta ve 0.5-4 Hz arasındaki dalgalara delta adı verilmiştir.

Delta dalgaları genellikle düşük frekanslı yüksek genlikli dalgalardır. Genlikleri 20-400 mikrovolt arasında değişmekte ve 0.5-4 Hz lik bir frekans bandına sahiptirler.

Frekansları 4-8 Hz arasında, genlikleri 5-100 mikrovolt arasında değişen beyin dalgalarına teta dalgaları adı verilmektedir. Bu dalgaların hasta uyanırken ortaya çıkması.....

3.1.2.2. Kompleks Dalgalar

Kompleks dalgalar, adından da anlaşıldığı gibi sporadik dalgaların birleşmesiyle oluşmuştur. Kompleks dalgalarının en çok gözlenen biçimleri; dalga ve diken(wave and spike), çoklu diken ve dalga (multiple spike and wave) ve yavaş diken ve dalgadır(slow spike and wave). Dalga ve diken kompleksi 3Hz'lik frekans düzeninde oluşur. Genelde her iki hemisferde senkron olarak ortaya çıkar. Bu kompleks dalgalar, beyin sapı veya talamik retikuluma ait bozulmalar sonucu görülmektedir. Sürekli diken ve dalga kompleksinde, birkaç diken ardından, genelde 2-4 veya 6 dikenini , bir veya iki düzenli dalga izlemektedir. Bu anomali paterni, çoğu kere miyoklonik tipte İdyopatik Epilepsinin bir göstergesidir[14].

Yavaş diken ve dalga kompleksi daha çok çocuklarda gözlenen bir bioelektrik aktivitedir. Burada dikenler genelden daha uzun sürelidir. Bu kompleks dalgaların frekansı değişmekte olup çoğu kere 2 Hz civarındadır[14].

Diken, keskin dalga ve keskin-yavaş dalgalar daha çok epilepsi hastalıklarında rastlanmaktadır. Bu tip dalgalar, epilepsi hastalarında, genellikle bir tek noktadan algılanmaktadır. Epilepsi hastalarında en sık görüleni keskin-yavaş dalgalardır. Sadece keskin

dalgalar daha az sıklıkta görülürler ve en az görüleni diken dalgalarıdır. Epilepsi hastalığının teşhisinin yapılabilmesi açısından bu tür bulguların gözlenmesi oldukça önem taşımaktadır.

3.2. Epilepsi

Epilepsi teşhisinde EEG'nin tartışılmaz bir yeri vardır. İnteriktal(nöbet olmadığı dönem) ve iktal(nöbet esnasında) EEG, epilepsi teşhisi, sınıflaması, tedaviye yanıtın takibi ve epilepsi cerrahi tedavisi uygulanabilecek adaylarda epileptojenik alanın saptanmasında oldukça yararlıdır.Epileptiformunda ortaya çıkan dalgalar çalışmanın kompleks dalgalar bölümünde anlatılmıştır. İnteriktal EEG'de spesifik epileptiform paternler şunlardır:

- i. Diken dalga (spike)
- ii. Keskin dalga
- iii. Diken / yavaş dalga kompleksi
- iv. Temporal intermittant(aralıklı) ritmik delta aktivitesi
- v. PLEDs

Epileptiform deşarjların temelini, diken ve keskin dalgalar oluşturur. Diken dalgalar 20msn-70msn arasında değişen çok kısa süreli dalgalarıdır. Keskin dalga ise daha uzun süreli olup, 70msn-200msn arasında değişmektedir. Diken ve keskin dalgalar izole(tek başına)görülebilir ama sıklıkla bunları yavaş bir dalga takip eder ve diken yavaş dalga aktivitesini oluştururlar. Yavaş dalga bileşeni genellikle 150msn-300msn sürelidir ve sekonder inhibasyona bağlı uzamış hiperpolarizasyona bağlıdır. Bu epileptiform dalgalar tek tek veya tekrarlayıcı bir tarzda ortaya çıkabilir[2].

Diken ve keskin dalgalar EEG zemin aktivitesinden genellikle kolayca ayırt edilir. Bazı durumlarda ise bir potansiyelin gerçek epileptiform anormalliği veya epileptiform olmama durumlarını belirlemede, dalganın şekli kaynaklandığı alanın aktivitesi gibi bazı kriterleri dikkate almak gerekmektedir. Bu kriterler aşağıda tanımlanmıştır[2]:

- i. Bu dalganın şekli asimetriktir. Yani ilk çıkan kolu inen koluna göre daha diktir.
- ii. Bu dalgaların zemin aktivitesine göre frekansı daha farklıdır.
- iii. Bu dalgalar difazik veya trifazik konfigürasyondadır.
- iv. Bu dalgaları yavaş dalga bileşeni takip eder.

- v. Bu dalgalar, parsiyel başlangıçlı epilepsilerde yavaş bir zemin aktivitesinde ortaya çıkar.
- vi. Bu anormalliklerin fizyolojik bir potansiyel oluşturması ve elektrotu içermesi gerekir.

3.3 Gerçekleştirilen Sistemin Donanımı

Bu çalışma için gerçekleştirilen sistem, beyin işaretlerinin gerçek zamanda bilgisayara kaydedilmesi için tasarlanmıştır. Bu sistemin blok diyagramı Şekil-1 de gösterilmektedir.


Gerçekleştirilen sistem bilgisayar, arabirim Ünitesi, EEG cihazı elemanlarından oluşmaktadır.

Sistemde kullanılan bilgisayar Motorola-68030 mikroişlemci tabanlı bir Macintosh bilgisayardır. Bilgisayarın sahip olduğu SCSI (Small Computer System Interface) terminali ile EEG'den alınan analog beyin işaretlerini sayısal işaretlere çeviren arabirim ünitesi vasıtasıyla veriler gerçek zamanda bilgisayara aktarılır.

Arabirim Ünitesi iki ana bölümde incelenebilir. Bu bölümler, bilgisayar çevre sistem arabirimi (SCSI) ve analog/dijital dönüştürücüdür.

Gerçekleştirilen arabirim ünitesi bilgisayarın SCSI terminaliyle iletişim sağlar. SCSI, bilgisayar çevre sistemleri ve bilgisayar arasında bir iletişim birimi olarak kullanılan tipik bir yüksek hızlı sekiz bitlik paralel hat olarak tanımlanabilmektedir. Maksimum bilgi aktarma oranı 57.6 Kbyte/sn' dir. Yani bir 12 bitlik A/D örneğini depolamak için iki byte gerektiğinden dolayı maksimum örnekleme oranı 28,800 örnek/saniyedir[5].

Gerçekleştirilen arabirim ünitesinde kullanılan analog/dijital dönüştürücü (AD7572) %0.02 hassasiyete sahip ve dönüşüm süresi 0.014 ms olan 12-bitlik A/D dönüştürücüdür. Burada 12 bit seçicilik ile en düşük değerlikli bit, ± 10 V bölgesinde, 4.88mV'tur[5].



Şekil 1. Gerçekleştirilen sistemin donanımı

3.4. Wavelet(Dalgacık) Dönüşümü

İşaret çözümü yaklaşımının temel amacı uygun bir dönüşüm metodu uygulandıktan sonra işareten istenen bilgiyi elde etmektir. Uygulanan dönüşümün tersinebilir olması koşulu ile dönüştürülmüş biçimin orijinal işareti bire-bir temsil etmesi koşulu gerekmekte ve parametre kestirimi, kodlama, veri sıkıştırma ve örüntü tanıma gibi daha karmaşık işaret çözümü işlemlerinin, ilgili özelliklerin daha belirginleşeceği umulan, dönüştürülmüş işaret üzerinden gerçekleştirilmesi istenmektedir[6].

Özellikleri zamanla değişmeyen, başka bir deyişle durağan bir $x(t)$ işaretine uygulanabilecek en uygun dönüşüm Şekil-2 de gösterildiği gibi zaman domeni ile frekans domeni arasında bir ilişki sağlayan Fourier dönüşümüdür. Buna göre Fourier dönüşüm çifti

$$X(f) = \int_{-\infty}^{\infty} x(t) \exp(-j \frac{2\pi}{T} t) dt \quad (3.1)$$


$$x(t) = \int_{-\infty}^{\infty} X(f) \exp(j \frac{2\pi}{T} t) df \quad (3.2)$$

olarak tanımlanmaktadır. Tanımlardan anlaşılacağı gibi durağan bir $x(t)$ işareti sonsuz zaman aralığında tanımlı sinüzoidal taban işlevleri ile frekans domeninde tanımlanmaktadır. Ancak özellikleri zamanla değişen durağan olmayan işaretler söz konusu olduğunda Fourier dönüşümü işaretdaki herhangi bir anlık değişimi bütün frekans domenine yansıtacak ve işaretin özelliklerinin çıkartımında yeterli olmayacaktır.



Şekil 2. Fourier dönüşümü

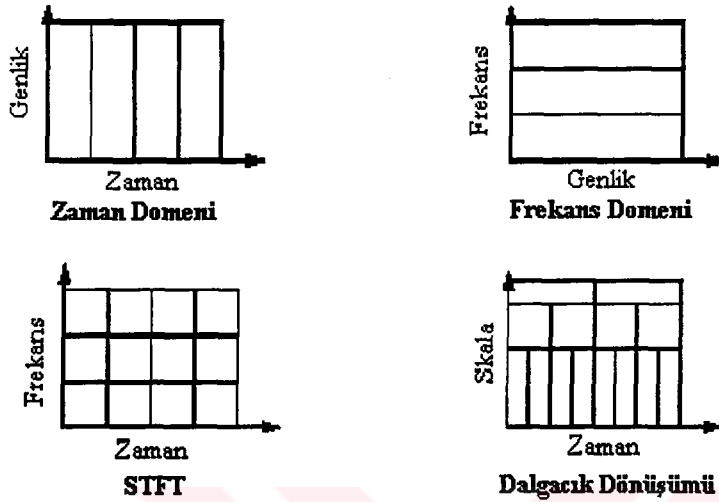
Bu eksikliği gidermek için DENNIS GABOR(1946) Fourier dönüşümünü zamanın belli bir bölümünde sadece işaretin bir kısmını analiz etmek için yeni bir teknik olarak adapte etti. Bu adapte durumuna sinyalin pencerelemesi adı verilmektedir. GABOR' un bu uyarlaması Kısa-zamanlı Fourier dönüşümü (Short-Time Fourier Transform(STFT)) olarak adlandırılır ve işareti zaman ve frekansın iki boyutlu bir fonksiyonu olarak haritalar (Şekil-3)[6].



Şekil 3. Kısa Zamanlı Fourier Dönüşümü


STFT işaretin zaman ve frekans tabanlı görünüşleri arasında bir nevi bağlantı sağlar. Yani STFT zamanın küçük aralıklarında işaretin içerdiği frekans hakkında bilgileri ortaya çıkarır. Fakat bu bilgilerin elde edilmesi bir koşula dayanmaktadır ve bu koşul pencerenin büyüklüğüyle belirlenir. STFT'nin, zaman ve frekans bilgileri arasındaki uyuşmayı göstermesindeki yararlığın yanı sıra dezavantajı, zamanda uygulanan pencerenin belirli bir uzunluğa sahip olmasıdır. Bu durumda da pencere bütün frekanslar için aynı kalmaktadır.

Dalgacık dönüşümü, değişen uzunluktaki bölgeleri kapsayan pencereleri içeren yeni bir teknik olarak karşımıza çıkmaktadır. Bu dönüşüm, düşük frekans bilgilerinin istendiği yerde geniş zaman aralığı, yüksek frekans bilgilerinin istendiği yerde kısa zaman aralığını parametre olarak kullanmaktadır. İşaretin zaman tabanlı, frekans tabanlı ve STFTsinin ve dalgacık dönüşümünün alındığı durumlardaki farklılıklar Şekil 4'te gösterilmiştir[6].



Şekil 4. İşaretin zaman, frekans tabanlı ve çeşitli şekillerde alınan dönüşümlerinin gösterilmesi

Fourier analizi, bir işaretin çeşitli frekans değerlerine sahip sinüs dalgalarına bölünmesi temeline dayanmaktadır. Benzer bir şekilde dalgacık dönüşümü de işareti orijinal(veya ana) dalgacığın kaydırılmış ve ağırlıklandırılmış versiyonlarına ayırmaktadır. Şekil-5'te bir sinüs dalgası ve bir ana dalgacık(db 10) prototipi verilmiştir.



Şekil 5. Bir sinüs dalgası ve bir ana dalgacık prototipi

Keskin değişimlere sahip işaretler için Fourier dönüşümü yetersiz kalmaktadır. Bu yüzden bu tür işaretlerin dalgacık dönüşümü kullanılarak analiz edilmesi daha uygun olmaktadır.

Dalgacık dönüşümünün temeli bir işareti dalgacık adı verilen temel bir fonksiyon kümesine dönüştürmeye dayanır. Bu temel fonksiyonlar dalgacık prototipi olarak adlandırılan bir tek(unique) fonksiyonun genişletilmesi, daraltılması ve kaydırılması suretiyle elde edilmektedir. $x(t)$ giriş işaretini de dikkate alarak ayrıştırma işlemi, Sürekli Dalgacık Dönüşümü(CWT) ve Ayrık Dalgacık Dönüşümü(DWT) olarak adlandırılan iki tür dalgacık dönüşüm yöntemi ile yapmak mümkündür.

3.4.1. Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü(CWT) , işaretin, Ψ dalgacık fonksiyonunun ağırlıklandırılması ve kaydırılmış haliyle çarpılıp tüm zaman boyunca toplanmasından elde edilir.

$$CWT(a,b)=\int x(t).\Psi^*_{a,b}(t).dt \quad (3.3)$$

burada;

$a \in \mathbb{R}^+$ ölçülendirme parametresi

$b \in \mathbb{R}^+$ dönüştürmeyi

* kompleks eşleniği ifade etmektedir

Sürekli dalgacık dönüşümünün sonucu, ağırlık ve pozisyonun fonksiyonu olan çok sayıda c katsayılarından oluşmaktadır.

$\Psi(t)$ den elde edilen $\Psi^*_{a,b}(t)$ fonksiyonu, a ölçeği ve b zamanında, aşağıdaki gibi yazılmaktadır.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (3.4)$$


Genellikle, dalgacık dönüşümü uygulamalarında, ana dalgacık olarak ortogonal diydik fonksiyonlar seçilmektedir. Buna göre a ve b parametrelerine bağlı olarak seçilen ana dalgacık aşağıdaki gibidir;

$$\Psi_{j,k}(t) = 2^{-j/2} \Psi(2^{-j}t - k) \quad (3.5)$$

burada $\{\Psi_{j,k}(t), j, k \in Z\} L^2$

3.4.1.1. Ağırlıklandırma


Bir dalgacığın ağırlıklandırılması ifadesi basitçe, işaretin genişletilmesi veya sıkıştırılması anlamına gelmektedir. Bununla birlikte ağırlıklandırma parametresi genellikle a ile verilmektedir. Şekil 6'da ağırlıklandırmanın nasıl yapıldığı örnek bazı ağırlıklandırma değerlerine göre gösterilmiştir.



Şekil 6. Ana dalgacığın ağırlıklandırılması

3.4.1.2. Kaydırma

Bir dalgacığı kaydırma, basitçe işareti başlangıcından geciktirme veya öncesine almaktır. Matematiksel olarak bir $f(t)$ fonksiyonunun k kadar kaydırılması $f(t-k)$ ile gösterilir. Şekil 7'de işaretler için kaydırma özelliğinin nasıl olduğu gösterilmiştir.



Şekil 7. Ana dalgacığın kaydırılması

3.4.1.3. İşaretlere Sürekli Dalgacık Fonksiyonunun Uygulanması

Sürekli dalgacık dönüşümü, bir işaretin ağırlıklandırılmış ve kaydırılmış ana dalgacık ile var olduğu zamanının tümünde çarpılıp toplanmasıyla elde edilmektedir. Bu işlem, ağırlık ve pozisyonun bir fonksiyonu olan dalgacık katsayılarını üretir.

Sürekli dalgacık dönüşümünün alınması kolay bir işlemdir. Aşağıda bu işleyişin nasıl yürüdüğü anlatılmıştır.


i. Bir dalgacık alın ve işaretin başlangıcındaki bir kesitle karşılaştırın

ii. İşaretle ilişkili olan bir C sayısı hesaplayın. C sayısının değerinin büyüklüğü dalgacığın işaretle ne kadar benzediğini ortaya çıkarmaktadır. C sayısı ne kadar büyük olursa dalgacıkla işaret o kadar benzeşiyor anlamına gelir. Yalnız dikkat edin ki bu seçeceğiniz dalgacığın şekline bağlı olacaktır (Şekil 8).




Şekil 8. Belirlenen C değerine göre işaretle dalgacığın karşılaştırılması

iii. Dalgacığı kaydırın ve işaretin tümünü kapsayacak şekilde i ve ii 'yi tekrarlayın(Şekil 9)



Şekil 9. Dalgacığın işaretin kesitleriyle karşılaştırılması

iv. Dalgacığı genişletin ve i'den iii'ye kadar tekrarlayın (Şekil 10)

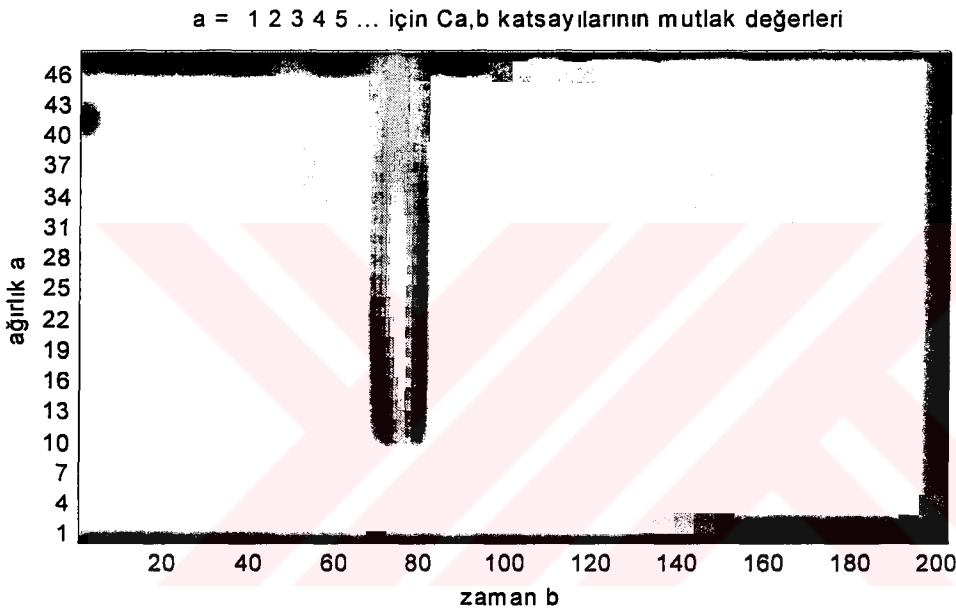


Şekil 10. C değerinin değiştirilip, dalgacık ile işaretin tekrar karşılaştırılması

v. Dalgacıđı ađırlıklandırın ve önceki aşamaları tekrarlayın.

Yukarda anlatılan prosedür yapıldığı zaman işaretin farklı kesitlerinde farklı ađırlıklandırmada üretilen katsayılar elde edilmektedir. Katsayılar, işaret üzerinde düzenlenen dalgacıkların regresyonunun sonuçlarını oluşturmaktadır[6].

Bu katsayıların ne anlama geldiđi sorusunu bir grafikte açıklayabiliriz. Bu grafiđin x ve y eksenleri sırasıyla işaretin(zamandaki) pozisyon ve ađırlık deđerlerini vermektedir. Buna ilaveten dalgacık katsayılarını ise x-y grafiđindeki her noktaya verilen renkle belirlemek mümkün olmaktadır.



Şekil 11. Farklı ađırlıklara göre işaretin dalgacık deđerlerinin bulunması

Şekil 11'de verilen dalgacık dönüşümü katsayıları koyu renkten açık renge doğru daha büyük deđerler almaktadır. Yani kullanılan programda büyük deđerler daha açık renkle ifade edilmiştir ve üç boyutlu bir grafiđi iki boyutlu bir düzlemde göstermek için renk tonlaması kullanılmıştır.

3.4.2. Ayrık Dalgacık Dönüşümü

Dalgacık katsayılarını her olası ađırlık için hesaplamak çok fazla işlem yapmayı gerektirmektedir ve bunun sonucunda aşırı sayıda fazla veri elde edilir. Bunun yerine ikinin

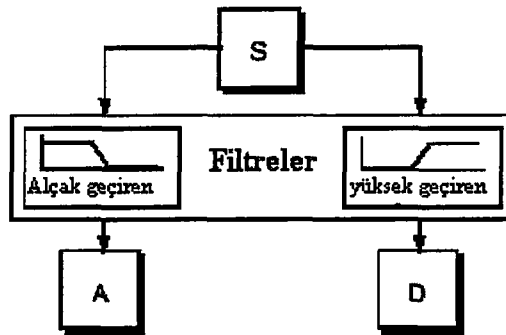
katlarını temel alacak bir şekilde ağırlıkları ve pozisyonu seçersek yapacağımız analizler çok daha etkin olacaktır. Dalgacık katsayılarını hesaplamada kullanılan bu prosedüre ayrık dalgacık dönüşümü(discrete wavelet transform(DWT)) denmektedir.

Bu işlemi gerçekleştirmek için uygulanan etkin bir yol 1988 yılında MALLAT tarafından filtreler kullanılarak geliştirilmiştir. MALLAT algoritması, işaret işleme topluluğu arasında iki-kanal alt bant kodlayıcı olarak bilinen bir klasik yoldu. Bu işlem, hızlı bir dalgacık dönüşümü yapan çok pratik bir filtre algoritmasıdır[6].

Bir çok işaret için sahip olduğu düşük frekanslı bileşenler önemlilik arz eder. Düşük frekans bileşenleri işaretler için genellikle tanınma özelliklerini içerir. Diğer yanda yüksek frekanslı bileşenler işaretin ana kısmına ilave nüanslardır. Buna örnek olarak insan sesini alırsak, sesin yüksek frekanslı bileşenlerini çıkartmanız durumunda ses farklılaşır fakat hala söylenen şeyleri duyarsınız, fakat düşük frekanslı bileşenlerin bir kısmını çıkarırsanız söylenen sözleri duyamazsınız.


Yukarıda anlatılan kavramlardan yola çıkarak, ayrık dalgacık dönüşümü için yaklaşımlardan(approximations) ve detaylardan(details) söz edebiliriz.

Dalgacık dönüşümünde kullanılan yaklaşımlar yüksek ağırlıklı, düşük frekanslı bileşenler ve detaylar düşük ağırlıklı yüksek frekanslı bileşenlerdir. Yani orijinal işaret(S) Şekil 12'de görüldüğü gibi birbirini tümleyen filtrelerden geçirilerek işaretin düşük ve yüksek frekanslı bileşenleri olmak üzere iki işarete ayrılmıştır.



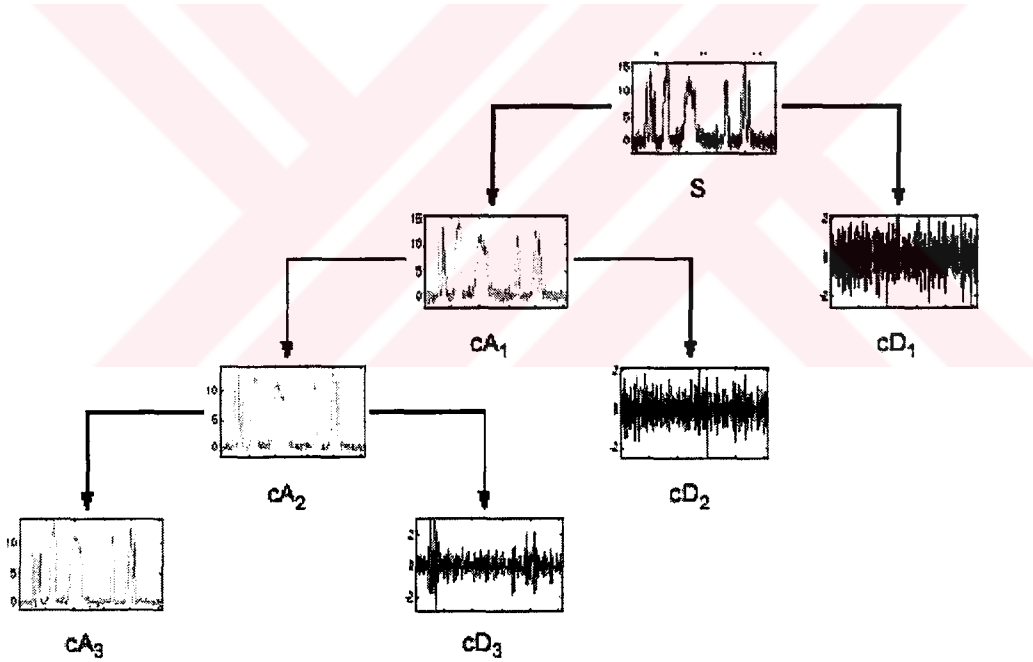
Şekil 12. İşaretin düşük ve yüksek frekanslı bileşenlerine ayrılması

Bu ayırma işlemi bir çok kez yapılabilir. Böylece bir işaret daha az çözünürlüklü bir çok alt bileşenine ayrılacaktır. Buna dalgacık ayrıştırma ağacı da denir (Şekil 12).



Şekil 13. Dalgacık ayrıştırma ağacı

İşaretin Şekil 13'teki gibi alt frekans bileşenlerine(yaklaşım ve detaylar) ayrılması olayı Şekil 14'te gösterilmiştir.



Şekil 14. Bir işaretin yaklaşım ve detaylarına ayrılması

3.4.2.1. Seviye Sayısı

Analizin iteratif olmasından dolayı, teoride bu işlem tanımsız olarak devam ettirilebilir. Fakat gerçekte ayrıştırma ancak detaylar bir tek örnek veya piksele denk düşmesi haline kadar devam edebilir. Pratikte işaretin doğasına veya entropi gibi bazı uygun kriterlere uygun bir seviye sayısı seçilir.


3.4.2.2. İşaretin Rekonstrüksiyonu

Buraya kadar, ayrık dalgacık dönüşümünün, işaretleri veya imajları analiz veya ayrıştırma için nasıl kullanıldığı anlatılmıştır. Bununla birlikte bilgi kaybına uğramadan işaretin tekrar elde edilmesi işlemine rekonstrüksiyon veya sentez denilir. Bu işlemin matematiksel manipülasyonuna Ters ayrık dalgacık dönüşümü (Inverse Discrete Wavelet Transform(IDWT)) denmektedir.

3.4.2.3. Paket Analizleri

Dalgacık paket metodu, işaret analiz olasılıklarını sağlayan dalgacık ayrıştırmasının geliştirilmiş bir halidir.

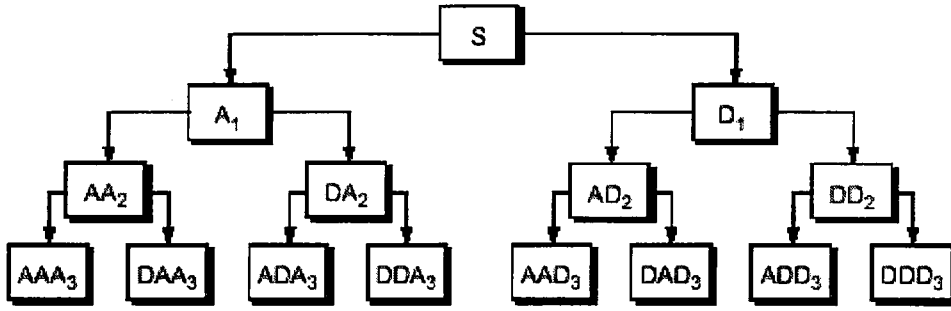
Dalgacık analizlerinde işaret yaklaşım ve detaylarına ayrılmaktadır. Daha sonra, yaklaşım tekrar kendi ikincil seviye yaklaşımı ve detayına ayrılır ve bu işlem bir çok kez tekrarlanabilir. Buna ilaveten n-seviye ayrıştırma için, işaretin ayrıştırılması veya tekrar oluşturulması yönünden n+1 olası yol kullanılabilir (Şekil 15).



$$\begin{aligned}
 S &= A_1 + D_1 \\
 &= A_2 + D_2 + D_1 \\
 &= A_3 + D_3 + D_2 + D_1
 \end{aligned}$$

Şekil 15. Dalgacık paket analizlerinde ayrıştırma

Dalgacık paket analizlerinde detaylar da yaklaşımlar gibi ayrılabilir. Bir işareti oluşturmada için 2^n farklı yol kullanılabilir. Buna dalgacık paket ayrıştırma ağacı denmektedir.



Şekil 16. Dalgacık paket ayrıştırma ağacı

Şekil 16'dan yola çıkarak S işaretinin bir sürü yoldan oluşturulabileceği söylenebilir. Buna örnek olarak $S = A1 + AAD3 + DAD3 + DD2$ verebiliriz. Fakat, bu temel dalgacık analizleriyle bulunamayacak bir gösterimdir.

3.5. Yapay Sinir Ağları

Modern bilgisayarların gün geçtikçe daha güçlü hale gelmeleriyle birlikte, bilim adamları insanlara göre daha kolay yapılabilecek işler üzerinde makineleri daha etkin kullanmaya cesaret etmişlerdir. Örnek olarak, bir öğretmenin birazcık yardımıyla kazanılan geçmiş sayesinde insanlar tarafından, bir A harfi kolayca tanımlanabilmekte veya bir kuş kediden ayrılabilir. Daha fazla deneyim ise insanlara cevaplarını belirlemeye ve performanslarını geliştirmeye yardım etmektedir[15].

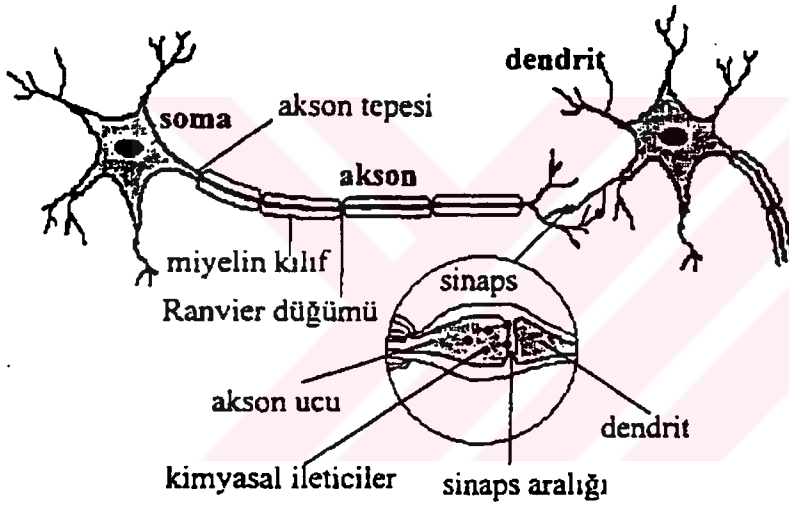
Klasik olarak, bir bilgisayarda aritmetik ve mantık işlemlerini ardışıl olarak işleyen bir işlemci bulunmaktadır. Bu işlemcilerin hızı günümüzde saniyede 1 milyardan fazla işlem yapabilme özelliğine sahiptir, ancak hala insanların yaptığı biçimde öğrenme ve yapılarını uyarlama yeteneğine sahip değildir.

Klasik bir bilgisayarla insan arasındaki bu farkı yaratan temel sebep, ne bilgisayarların işlem yapma hızından ne de onların işlem yapabilme yeteneğinden kaynaklanmaktadır. Günümüzdeki işlemciler beyindeki nöron adı verilen işlem birimlerinden, yani sinir hücrelerinden, 10^5 kattan fazla daha hızlı işlem yapabilme özelliğine sahiptir. İşlem yapabilme kapasiteleri karşılaştırıldığında ise, bir nöronun yapabildiği şeyler bir bilgisayar işlemcisiyle karşılaştırıldığında çok basit ve sınırlı kalmaktadır. Bütün bunlara rağmen aradaki fark, temel olarak yapısal özellik ve işleme tekniğinden kaynaklanmaktadır. Yani klasik bilgisayarlarda komutlar çok karmaşık ve de çok hızlı bir işlemci tarafından ardışıl olarak işlenirken, beyindeki işaretler daha basit ve yavaş, ancak aralarında yoğun bir bağlantı ağı bulunan çok sayıda nöron tarafından paralel olarak işlenmektedir.

3.5.1. Biyolojik Nöron

İnsanın merkezi sinir sisteminde yaklaşık 1.3×10^{10} nöron bulunmaktadır ve bunların yaklaşık 1×10^{10} kadarı beyinde yer alır. Herhangi bir zamanda, bu nöronların bir kısmı ateşleme yapmakta, yani art arda gelen **uyartı** (kısa süreli işaret) katan üretmektedir. Bu elektriksel aktivitede yaklaşık 10 watt enerji tüketilmektedir. Uyku sırasında bile saniyede yaklaşık 5×10^7 uyartı, beyin ve vücudun diğer parçaları arasında gidip gelmektedir. İnsan uyanırken bu sayı önemli bir biçimde artmaktadır[15].

Bir nöronda soma adı verilen ve kabaca küresel bir biçimi olan hücre gövdesi bulunur. (Şekil 17). Soma tarafından üretilen işaretler akson adı verilen uzantılar aracılığı ile diğer nöronlara iletilmektedir. Soma etrafındaki çalı dallan gibi gözüken diğer uzantılar ise dendrit olarak adlandırılmaktadır. Dendritler diğer nöronlardan gelen işaretleri toplamaya yaramaktadır.




Şekil 17. Biyolojik bir nöronun yapısı

Bir aksonun bağlantı yapacağı nöronla arasındaki uzaklığa bağlı olarak bir milimetrenin onda birinden bir metreye kadar değişebilir. Aksonların uç tarafı bir çok dala ayrılır ve bu dalların en ucunda diğer nöronlarla bağlantı yapmayı sağlayan sinapslar bulunur.

Bir nöron sinaptik bağlantıları dolayısıyla çok sayıda nörondan uyarım alır. Akson ucuna ulaşan uyartılar kimyasal ileticilerin sinaptik aralığa dökülmesine neden olur. Kimyasal ileticilerin türüne göre alıcı nörondaki potansiyel etkilenir. Sinapstaki uyarımlar dereceli potansiyel olarak adlandırılan nöron potansiyelini artırarak depolarizasyona neden oluyorsa bu tür sinapslara uyarıcı sinaps denir. Dereceli potansiyelin artmasını engelliyerek hiperpolarizasyona sebep olan kimyasal ileticiler taşıyan sinapslar ise ketleyici sinaps olarak adlandırılır. Dereceli potansiyeldeki depolarizasyon belirli bir eşik değerini atlamaya yeterliyse alıcı nöron ateşlemeye başlar. Genelde, tek bir sinapstan dolayı oluşan

depolarizasyon nöronun ateşlemesi için yeterli değildir, ancak eğer aynı zamanda o nöronun başka uyarıcı sinapslarından da etkiler geliyorsa, bunların toplu etkisi dereceli potansiyelin eşik değerini atlayarak nöronun ateşlemesine yetebilir.

Ateşleme akson tepesinde başlar ve o bölgedeki zarın seçici geçirgenlik özelliği bir süre için kesintiye uğrar, böylece iyonlar hücre zarından doğal biçimde süzülürken zarın iç ve dışındaki iyon konsantrasyonları eşit hale gelir. Eğer depolarizasyon yeteri kadar büyükse daha önce negatif olan iç potansiyel sonunda sıfırlanır ve kısa bir süre için pozitif hale geçer. Potansiyeldaki bu kısa süreli ters dönüş aksiyon potansiyeli olarak adlandırılır ve aksiyon potansiyelinin bulunduğu bölgeden aksonun dinlenme potansiyelindeki yakın bölgelerine doğru elektrik akımı oluşur. Bu akım dinlenme potansiyelinde bulunan bir sonraki bölgedeki zarın geçirgenlik özelliğini etkiler ve böylece uyarı akson zarı boyunca ilerler (Şekil 18).



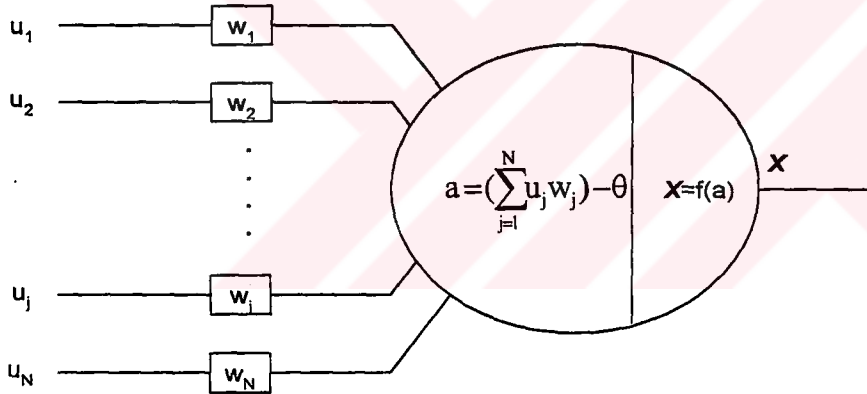
Şekil 18. Nöronlarda iletim

Aksiyon potansiyeli aksonda bir noktadan geçtiğinde o bölge duyarsız dönem olarak adlandırılan bir süre için yeniden uyarılma yeteneğini kaybeder. Bu bölge, duyarsız dönem süresine aktif hale gelemediğinden, uyarı aksonda yalnızca ileri doğru iletilir, geri yönde gitmez. Daha önce uyarılmış bölge kısa sürede dinlenme potansiyeline geri döner ve yeni uyarıları iletmeye hazır hale gelir. Duyarsız dönem yaklaşık 1 milisaniye civarındadır ve bu durum iletilecek uyarı sayısını kısıtlar. Tipik bir nöron saniyede 1000 uyarı ile sınırlıdır. Bir nörondaki dereceli potansiyelin ateşlemeye yeterli olup olmaması o nöronun sinapslarına ulaşan uyarı sayısı ve sıklığına bağlıdır. Eğer uyarılma yeterli değilse, dereceli potansiyel azalarak normal durumuna döner. Diğer yandan, uyarılma yeteriyse dereceli potansiyel eşik değerine ulaşır ve akson tepesinde ateşleme başlayarak uyarılar oluşur. Akson tepesinde oluşan uyarılar buradan sinapslara kadar yok olmadan ilerler.

Aksonlar genellikle yalıtkan miyelin kılıfla kaplıdır. Uyarıların aksonda ilerleme hızı hücre zarından iyon transferini engelleyen miyelin kılıfın kalınlığına bağlıdır. Miyelin kılıf, düzenli aralıklarla Ranvier düğümü adı verilen noktalarda kesintiye uğrar. Hücre zarı ancak Ranvier düğümlerinde hücre dışı sıvı ile temas eder ve buralarda iyon değişimi olur. Dolayısı ile aksiyon potansiyeli Ranvier düğümleri üzerinde oluşan depolarizasyonlarla ilerler. Bir düğümdeki depolarizasyon, bir sonraki düğümü etkiler ve uyarılar düğümden düğüme sırayla atlayarak daha hızlı bir şekilde ilerlerler.

3.5.2. Yapay Nöron Modeli

Daha önceki bölümde açıklanmaya çalışıldığı gibi, gönderici nörondaki uyarıların alıcı nörondaki uyarımı, akson ucunda bulunan özel kimyasal ileticilerin sinaps aralığına dökülmesiyle oluşan oldukça karmaşık elektro-kimyasal bir olaydır. Bunun alıcı nörondaki etkisi, somadaki dereceli potansiyelin artması ya da azalması biçiminde ortaya çıkar. Eğer dereceli potansiyel bir eşik değerine ulaşabilirse nöron ateşlemeye başlar. 1943'te McCulloch ve Pitts tarafından önerilen yapay nöron modelinde yaratılmaya çalışılan işte bu özelliştir. Şekil 3'te gösterilen bu nöron modeli, üzerindeki bazı ufak değişiklikler yapılarak bu gün hala yapay sinir ağlarında yaygın biçimde kullanılmaktadır.



Şekil 19. Yapay nöron

Şekilde verilen yapay nöronda u_1, u_2 ile gösterilen N tane giriş bulunmaktadır. Bu girişleri nörona bağlayan her bir hatta w_1, w_2, \dots, w_N ile gösterilen bağlantı kuvvetleri atanmıştır. Yapay nöron modelindeki bağlantı kuvvetleri biyolojik nöronlardaki sinapsların etki kuvvetine karşılık gelir. Nöronun ateşleyip ateşlememesini belirleyen değeri yapay nöronda genellikle 0 ile gösterilir ve nöron uyarımı aşağıdaki denklemlerle ifade edilir.

$$a = \left(\sum_{j=1}^N w_j u_j \right) + \theta \quad (3.6)$$

Girişler ve bağlantı kuvvetleri reel sayılardır. Negatif bağlantı değerleri ketleyici sinapsları temsil ederken, pozitif değerler uyarıcı sinapsları temsil ederler. Biyolojik nöronda girişler negatif değer almazken, amacına bağlı olarak yapay nöronda bu kısıtlama kaldırılabilir. Bu serbestlik 0 için geçerlidir. Matematiksel kolaylığından dolayı, uyarım denkleminde genellikle 0 dan önce + işareti kullanılır, ancak 0'ın kendi değeri negatif ya da pozitif olabilir. Basitleştirme amacıyla bazen nöronun hayali bir $UQ = -1$ girişine $w_0=0$ ağırlık kuvveti ile bağlı olduğu varsayılarak, toplam alt sınır 1 yerine 0'dan başlatılıp 0 toplam içine çekilebilir. Böylece uyarım formülü:

$$a = \sum_{j=0}^N w_j u_j \quad (3.7)$$

haline dönüşür. Biyolojik nörondaki ateşleme sıklığı ile ilişkilendirilerek, nöronun x ile gösterilen çıkış değeri uyarımın bir fonksiyonu olarak yazılır:

$$x = f(a) \quad (3.8)$$

vektör notasyonu kullanılırsa

$$a = w^T u + \theta \quad (3.9)$$

olur Burada w ve u


$$w = \begin{bmatrix} w_1 \\ w_2 \\ \dots \\ w_j \\ \dots \\ w_N \end{bmatrix}, \quad u = \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_j \\ \dots \\ u_N \end{bmatrix} \quad (3.10)$$

vektörleridir. Her iki vektör de N boyutundadır ve

$$w^T u = \begin{bmatrix} w_1 & w_2 & \dots & w_j & \dots & w_N \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_j \\ \dots \\ u_N \end{bmatrix} = \sum_{j=1}^N w_j u_j \quad (3.11)$$

olduğundan w^T u tek boyutludur.

Orijinal McCulloch-Pitts modelinde, çıkış fonksiyonu $F(a)$ bir eşik fonksiyonu olarak önerilmiştir. Ancak doğrusal, yokuş ve sigmoid fonksiyonları da Şekil 20’de gösterildiği gibi yapay sinir ağlarında yaygın olarak kullanılmaktadır. Bazı özel yapay sinir ağlarında çan eğrisi biçiminde olan Gauss fonksiyonu eşik fonksiyonu olarak kullanılmaktadır.



Şekil 20. Uyarım fonksiyonları

Yapay sinir ağlarında kullanılan eşik fonksiyonlarının matematiksel karşılıkları aşağıdaki gibidir.

$$\text{Eşik} \quad f(a) = \begin{cases} 0 & a \leq 0 \\ 1 & 0 < a \end{cases} \quad (3.12)$$

$$\text{Doğrusal} \quad f(a) = \kappa a \quad (3.13)$$

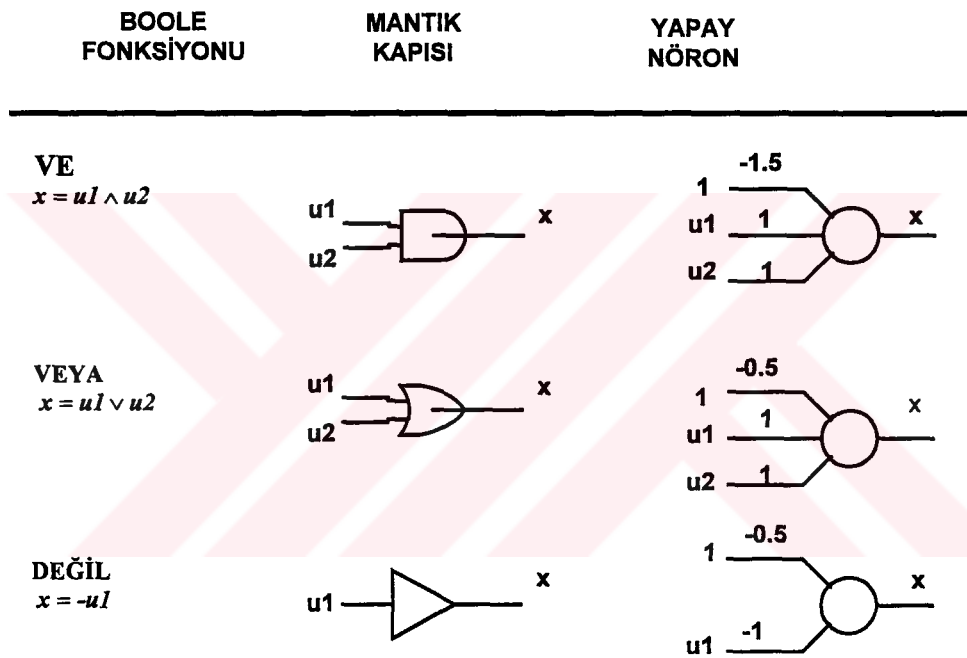
$$\text{Yokuş} \quad f(a) = \begin{cases} 0 & a \leq 0 \\ a/\kappa & 0 < a \leq \kappa \\ 1 & \kappa < a \end{cases} \quad (3.14)$$

$$\text{Sigmoid} \quad f(a) = \frac{1}{1 + e^{-\kappa a}} \quad (3.15)$$

$$\text{Gauss} \quad f(a) = \frac{1}{\sqrt{2\pi\sigma}} e^{-(\sigma-\mu)^2 / 2\sigma^2} \quad (3.16)$$

Basit yapısına rağmen McCulloch-Pitts nöronu kuvvetli bir sayısal işlem elemanıdır. Klasik sayısal bilgisayarların yapabileceği herhangi bir hesaplamanın, bir ağ ile birbirine bağlanmış nöronlar tarafından yerine getirilebileceği McCULLOCH ve PITTS tarafından ispatlanmıştır.

İkili mantık işlemlerini gerçekleştirmek üzere tasarlanan VE, VEYA ve DEĞİL kapıları, bilgisayar işlemcilerindeki aritmetik ve mantık birimi oluşturmada kullanılan temel yapıtaşlarıdır. VE, VEYA ve DEĞİL Boole mantık fonksiyonlarını kullanarak herhangi bir ikili mantık fonksiyonunu veya matematiksel işlemi gerçekleştirecek sayısal devreyi tasarlamak mümkündür. Bu fonksiyonların sayısal devre karşılıkları ve yapay nöronlarla nasıl gerçekleştirilebilecekleri Şekil 21’de gösterilmiştir.



Şekil 21. Mantık fonksiyonlarının yapay nöronlarla gösterimi

Yukarıdaki şekilde kullanılan bütün nöronlarda eşik fonksiyonu kullanılmıştır. Dolayısı ile çıkış değerleri de 0 ya da 1 değeri alabilen ikili değişkenlerdir. Nöronların bağlantı kuvvetleri ve eşik değerleri seçilen Boole mantık fonksiyonunu gerçekleştirmek üzere ayarlanmıştır. Giriş değerleri $u_i \in \{0,1\}$, $i = 1, 2$ seçildiğinde birinci nöronun çıkışı VE, ikinci nöronun çıkışı VEYA ve üçüncü nöronun çıkışı DEĞİL fonksiyonunun alması gereken değerleri alır.

3.5.3. Yapay Sinir Ağlarının Yapısı

VE, VEYA ve DEĞİL dışındaki bazı fonksiyonları tek bir nöron ile gerçekleştirmek mümkün değildir. Bu problem ancak bazı nöronların çıkışlarını diğerlerinin girişlerine bağlamak sureti ile kolaylıkla çözülebilir. Bu şekilde birbirlerine bağlanan yapay nöronlara nöral ağ ya da yapay sinir ağı denmektedir. Eğer yukarıda anlatılan nöronları bir ağ oluşturacak biçimde birbirlerine bağlarsak, bu durumda sistemimizde bir çok nöron bulunur ve bu nöronları birbirinden ayırt etmek için her bir nörona bir indis atarsak, bu durumda i indisli nöronun çıkışı ve uyarılmasını belirten denklemler aşağıdaki hale gelir.

$$x_i = f_i(a_i) \quad (3.17)$$

$$a_i = \left(\sum_{j=1}^N w_{ji} x_j \right) + \theta_i \quad (3.18)$$

Uyarılma denkleminde gözüken x_j diğer bir nöronun çıkışı ya da dışardan alınan bir giriş olabilir. İkinci durumda

$$x_j = u_i \quad (3.19)$$

kabul edilir.

Bazı uygulamalarda dışardan alınan tüm girişlerin ağı yalnızca özel giriş nöronları üzerinden bağlandığı varsayılır. Giriş nöronlarında $x_j = u_i$ ve $f_i(a) = a$ seçilmek sureti ile bu nöronların kendilerine bağlanan giriş değerlerini doğrudan çıkışlarına vermeleri sağlanır. Bir yapay sinir ağı için tüm nöron çıkışları ve eşik değerleri birer vektör halinde ifade edilebilir:

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_i \\ \dots \\ x_N \end{bmatrix}, \quad \theta = \begin{bmatrix} \theta_1 \\ \theta_2 \\ \dots \\ \theta_i \\ \dots \\ \theta_N \end{bmatrix} \quad (3.20)$$

Burada x_i ve θ_i , i nöronuna ait çıkış ve eşik değerleridir. Ayrıca ağıdaki tüm bağlantı ağırlıkları bir W matrisini oluşturmaktadır.

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1i} & \dots & w_{1N} \\ w_{21} & w_{22} & \dots & w_{2i} & \dots & w_{2N} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ w_{j1} & w_{j2} & \dots & w_{ji} & \dots & w_{jN} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ w_{N1} & w_{N2} & \dots & w_{Ni} & \dots & w_{NN} \end{bmatrix} \quad (3.21)$$

Buradaki w_{ji} , j nöronundan i nöronuna olan bağlantının kuvvetidir. W matrisinin kolonunu oluşturan

$$w_i = \begin{bmatrix} w_{1i} \\ w_{2i} \\ \dots \\ w_{ji} \\ \dots \\ w_{Ni} \end{bmatrix} \quad (3.22)$$

vektörü, aslında i nöronuna ait bağlantı vektörüdür.

Tüm ağı temsil etmek üzere basitçe

$$x = f(W^T x + \theta) \quad (3.23)$$

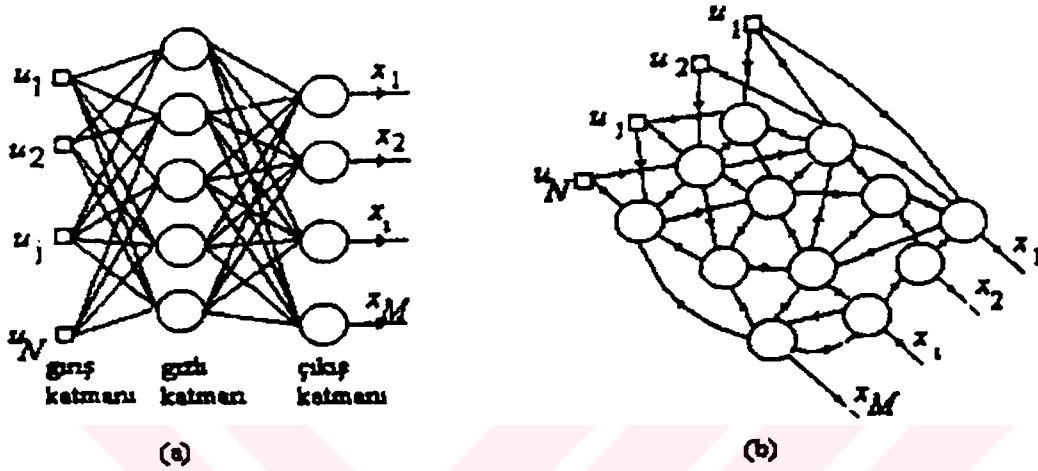
kullanılabilir. Burada

$$f = \begin{bmatrix} f_1(.) \\ f_2(.) \\ \dots \\ f_i(.) \\ \dots \\ f_N(.) \end{bmatrix} \quad (3.24)$$

bir vektör fonksiyonudur ve $f_i(.)$, i nöronuna ait çıkış fonksiyonuna karşılık gelir.

3.5.3.1. Ağ Yapıları

Gerçek uygulamalarda kullanılan yapay sinir ağları, bir çok nöronun birbirlerine çeşitli yapılarda bağlanmasıyla oluşturulmaktadır. Aralarındaki bağlantıların yapısına göre bu ağlar çeşitli sınıflara ayrılırlar . Bu sınıflandırmalardan olan çok katmanlı ve ileri beslemeli ağ , katmasız ve geri beslemeli ağ Şekil 22’de gösterilmiştir.



Şekil 22. a) çok katmanlı ve ileri beslemeli ağ b) katmansız ve geri beslemeli ağ

İleri beslemeli yapay sinir ağlarında nöronlar birbirlerine katmanlar oluşturacak şekilde bağlanmıştır. Bir katmandaki nöronlar girişlerini bir önceki katmandan alırlar ve çıkışlarını bir sonraki katmana beslerler. Bu tip ağlarda, aynı katmandaki nöronlar arasında ya da ileri katmanlardaki nöronlardan önceki katmanlardaki nöronlara bağlantı bulunmaz. İlk katman giriş katmanıdır ve dışarıdan alınan ağ girişleri bu katmandaki nöronlara bağlanır. Son katman çıkış katmanıdır ve ağın çıkışları bu katmandan alınır. Giriş katmanı ile çıkış katmanı arasındaki katmanlara ise gizli katman denir. Çok katmanlı bir ağda bir veya daha fazla gizli katman bulunabilir. İleri beslemeli yapay sinir ağlarında ağ çıkışındaki değerler, ağ girişindeki değerlerin bir fonksiyonu olarak yazılabilir.

Geri beslemeli ağlarda katmanlar olması gerekli değildir. Amacına göre katmanlar da kullanılabilir. Bir katmandaki nöronlar arasında ya da ileri bir katmandan geriye doğru bağlantı yapılabilir. Geri beslemeli yapay sinir ağlarında, ağ çıkışlarındaki değerler yalnızca ağ girişlerinin bir fonksiyonu olarak yazılamaz. Bu tür ağlar dinamik sistem özelliği gösterirler, yani çıkış değerlerinin ne olacağı uygulanan giriş değerlerine ve sistemin o andaki durumuna bağlıdır.

3.5.3.2. Yapay Sinir Ağlarının Eğitilmesi

Beyinde bilginin ne şekilde saklandığı ve nasıl çağırıldığı tam olarak bilinmemektedir. Ancak bu konuda yapılan deneysel çalışmalarda, belirli uyarıların düzenli olarak uygulandığı nöronların yapısında bazı değişikliklerin meydana geldiği gözlenmiştir. Düzenli uyarılar karşısında oluşan en önemli değişiklikler sinapsların elektriksel ve kimyasal özelliklerinde ortaya çıkmaktadır. Örneğin, sinaps aralığına dökülen kimyasal iletili miktarı artmakta ya da eksilmekte, veya sinaps sonrası nöronun iletili nöronlara tepkisi değişebilmektedir. Sonuçta öğrenme, sinaps sonrası nörona ulaşan uyarıların bu nöronun dereceli potansiyelinin eşik değerine ulaşmasındaki önemini değiştirmekle ilişkilidir. Yapay sinir ağlarında bu durum, bağlantı kuvvetlerini ve eşik değerini değiştirmek suretiyle modellenmektedir.

3.5.4. Perseptron ve Eğitim Algoritması

1950'li yılların sonlarına doğru bir öğrenme algoritması ile birlikte önerilen Perseptron, 1 sürekli giriş değerleri alabilen bir nöron modelidir. Perseptron daha önce açıklanan yapay nöron modeli ile aynı prensiplere göre çalışır ve Perseptron uyarımı, daha önce olduğu gibi

$$a = w^T + \theta \quad (3.25)$$

denklemleri ile tanımlanmıştır. Ancak çıkış fonksiyonu için +1 ve -1 değeri alabilen

$$f(a) = \begin{cases} +1 & a \leq 0 \\ -1 & 0 < a \end{cases} \quad (3.26)$$


kaydırılmış eşik fonksiyonu kullanılmaktadır. N girişli bir perseptron için,

$$w^T + \theta = 0 \quad (3.27)$$

yani

$$w_1 u_1 + w_2 u_2 + \dots + w_N u_N = 0 \quad (3.28)$$


denklemleri R_n giriş uzayında bir hiper-düzlem tanımlar. Bu hiper-düzlem denklemleri, $N=3$ için bir düzlem denklemine, $N=2$ için bir doğru denklemine iner. Perseptronun belirlediği hiper-düzlem giriş uzayını iki parçaya ayırır, öyle ki düzlemin bir tarafında perseptron çıkış değeri +1, diğer yanında ise çıkış değeri -1'dir (Şekil 23).



Şekil 23. Perseptron

Bir perseptronun bağlantı kuvvetleri ve eşik değeri tarafından belirlenen hiper-düzlem, giriş uzayını iki karar bölgesine ayırmaktadır. Hiper-düzlemin bir tarafında çıkış değeri +1, diğer tarafında ise -1 olur. Dolayısı ile perseptron, her hangi bir giriş vektörünün, örneğin A ve B olarak adlandırılan iki sınıftan hangisine ait olduğuna karar vermede kullanılabilir. Örneğin eğer çıkış +1 ise uygulanan giriş A sınıfına ve eğer çıkış -1 ise B sınıfına aittir denilebilir.

Örnek: u_1 ve u_2 alınan kan testi ile elde iki değişken olsun. Sağlıklı kişilerden alınan kan örneklerinde, bu değişkenlerin değerlerinin Şekil 24'da verilen A bölgesine, hasta kişilerden alınan kan örneklerinde ise B bölgesine düştüğünü varsayalım. Bu durumda giriş uzayı sadece 2 boyutludur ve perseptronun belirlediği bir doğru tanımlar. Bu doğru u_1 ve u_2 değişkenlerinin oluşturduğu uzayı ikiye böler. Şekil 24'te verilen A ve B sınıflarının elemanları bu doğru tarafından ayrılmaktadır. Ancak değişik w_1 , w_2 ve θ değerleri için bu doğrunun yeri ve yönü değişik olacaktır.



Şekil 24. Perseptron tarafından belirlenen hiper-düzlem giriş uzayını iki karar bölgesine ayırır. İki boyutlu uzayda bu hiper-düzlem bir doğru denkleminde iner.

Perseptron eğitim algoritmasının amacı başlangıçta rasgele seçilen w ve θ değerlerini öğrenme ilerledikçe A ve B sınıflarını ayırabilecek şekilde ayarlamaktadır. Bu algoritma aşağıda verilmiştir. Algoritmada $w(t)$, w vektörünün t anındaki değerini temsil etmektedir, $w_0(t)=\theta$ eşik değerine karşılık gelmektedir. Algoritma $t = 0$ için başlamakta ve her döngüde t , bir artırılarak ilerlemektedir.

3.5.4.1. Perseptron Eğitim Algoritması

- Bağlantı kuvvetleri ve eşik için ilkdeğer ata:

$w(0)$ vektöründe $j=0,1,2,\dots,N$ için $w_j(0)$ elemanlarına sıfırdan farklı küçük rasgele küçük değerler ver.

- Girişe yeni bir örnek giriş uygula ve arzu edilen çıkışı bildir:

Rasgele bir u^k örnek vektörü seçerek perseptron girişine uygula ve ayrıca arzu edilen y^k değerini belirle

$$y^k = \begin{cases} +1 & u^k \in A \\ -1 & u^k \in B \end{cases} \quad (3.29)$$

- Gerçek çıkışı hesapla:

$$x^k = f(w^T u^k) \quad (3.30)$$

- Bağlantı kuvvetlerini değiştir:

$$w(t+1) = w(t) + \eta.(y^k - x^k(t)) u^k \quad (3.31)$$

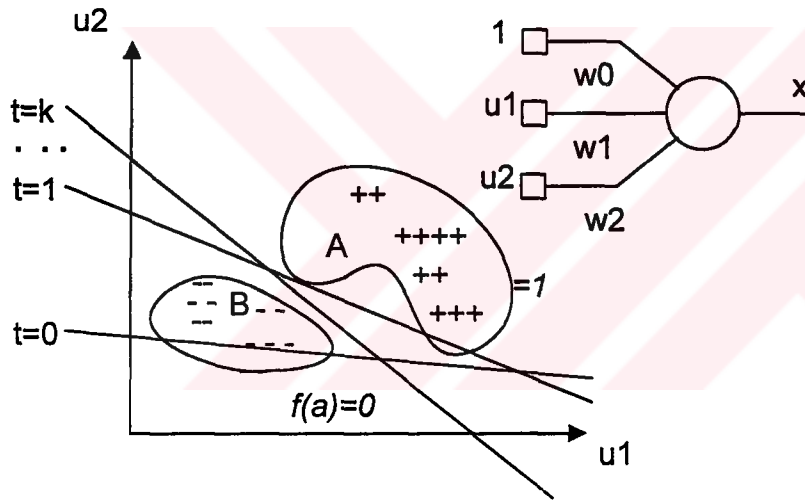
Burada $0 < \eta < 1$ öğrenme katsayısıdır.

- Döngü:Gerçek ve arzu edilen çıkış değerleri arasında fark kalmayınca kadar 2-4 adımlarını tekrarla

Başlangıçta bağlantı kuvvetleri ve eşik için sıfırdan farklı rasgele küçük değerler atanmaktadır. Daha sonra girişe bir u örnek vektörü uygulanmakta ve bu giriş değeri için perseptronun gerçek çıkış

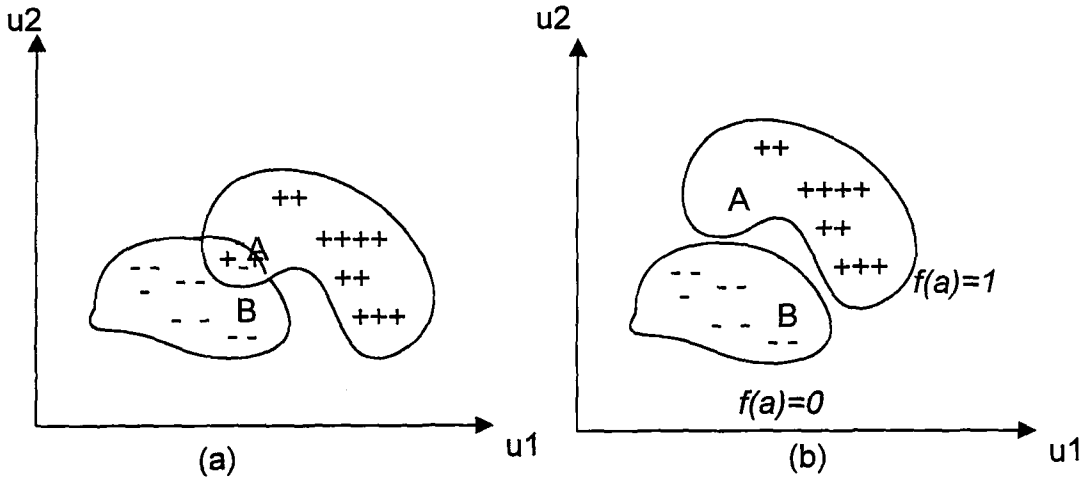
değeri ile arzu edilen çıkış değeri arasındaki farka bakılarak bağlantı kuvvetleri değiştirilmektedir. Adım 4'teki bağlantı kuvveti değiştirme denkleminde dikkat edilirse, bağlantı kuvvetlerinin ancak hata olduğu durumda, yani perseptron tarafından verilen karar ile arzu edilen karar farklı olduğunda değişime uğradığı, perseptronun doğru karar verdiği durumlarda ise bir değişime uğramadığı görülür. Bağlantı kuvveti değiştirme denkleminde kullanılan öğrenme katsayısı η , 0 ve 1 arasında değer almaktadır. Eğer η yeteri kadar küçük seçilmediyse, bağlantı kuvveti değiştirmede osilasyon meydana gelebilir, yani bağlantı kuvvetleri bir yere yakınsamadan sürekli değişebilir. Diğer yandan, eğer η çok küçük seçilmişse yakınsama olur ancak öğrenme çok yavaşlar.

Örnek: Bir önceki örnekte verilen A ve B sınıfları için, perseptron parametreleri ile belirlenen doğrunun öğrenme sırasında nasıl değiştiği Şekil 25'te gösterilmiştir. Başlangıçta bu doğru A ve B sınıflarını ayıramazken, sonunda bunları ayıracak hale gelir.



Şekil 25. Perseptron yakınsaması

Eğer giriş örneklerinin alındığı sınıflar doğrusal ayrılabilir ise, yani bu sınıflar herhangi bir hiperdüzlemin iki ayrı tarafında yer alıyorsa, perseptron öğrenme algoritmasının mutlaka yakınsayacağı ve perseptron tarafından belirlenen düzlemin bu iki sınıfı ayıracak bir pozisyona yerleşeceği ispatlanmıştır. Sınıflar doğrusal ayrılmaz olduğu veya üst üste bindiği durumlarda (Şekil 26) ise perseptron eğitim algoritması yakınsamaz ve karar sınırı sürekli değişerek osilasyona girer.



Şekil 26 (a) üst üste dağılım (b) doğrusal ayrılmaz dağılım

Üst üste binen dağılımlarda, hatayı 0'a indiren hiper-düzlem yerine bunu minimuma indiren bir hiper-düzleme yakınsamak amaçlanır. Doğrusal ayrılmaz sınıflar ise birden fazla perseptronun katmanlar halinde bağlanması suretiyle ayırt edilebilirler. Tek ve çok katmanlı perseptronların ayırt edebileceği karar bölgeleri Şekil 27'de gösterilmiştir. Perseptron öğrenme algoritması tek perseptron için geliştirilmiştir. Çok katmanlı ağların eğitimi için daha karmaşık algoritmalar kullanmak gerekir.

AĞ YAPISI	D-VEYA PROBLEMİ	DOĞRUSAL AYRILAMAZ BÖLGE	GENEL KARAR BÖLGELERİ


Şekil 27. Tek veya çok katmanlı perseptron tarafından oluşturulabilen karar bölgeleri

3.5.5. Çok Katmanlı Yapay Sinir Ağı'nın Geri-Yayılım Algoritması İle Eğitilmesi

Geri-yayılım algoritması, çok katmanlı ileri beslemeli yapay sinir ağlarının eğitilmesi için geliştirilmiştir. Her noktada türevinin tanımlı olması dolayısı ile nöron çıkış fonksiyonu olarak aşağıda verilen kaydırılmış sigmoid fonksiyonu kullanılır.

$$f(a) = \frac{2}{1 + e^{-ka}} - 1 \quad (3.32)$$

böylece çıkış değeri a 'ya bağlı olarak -1 ve $+1$ arasında değişmektedir.



Şekil 28. Geri yayılım algoritması için nöron çıkış fonksiyonu

Aşağıdaki Şekil 29'da çok katmanlı bir sinir ağı verilmiştir. Saklı katman ve çıkış katmanlarını ayırt edebilmek için l ve o indisleri kullanılmıştır. Ayrıca herhangi bir katmandaki nöronu belirleyebilmek için h , giriş katmanındaki nöronlar için j ve çıkış katmanındaki nöronları belirleyebilmek için i indisi kullanılmıştır.

Böyle bir ağda, çıkış katmanında yer alan i nöronunun çıkışı

$$x_{io}^k = f_o(w_{io}^T x_L^k) \quad (3.33)$$

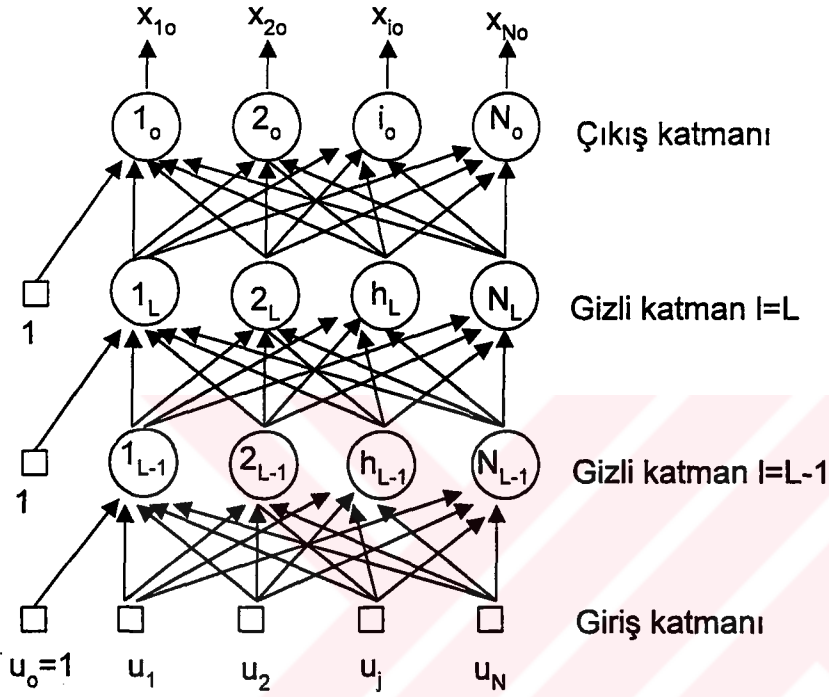
olarak yazılabilir. Buradaki x_L^k , gizli katmanda yer alan çıkış vektörüdür. Çıkış katmanındaki nöronların girişleri $l=L$ gizli katmanından alınmaktadır. Herhangi bir l katmanındaki h nöronunun çıkışı;

$$x_{hl}^k = f_l(w_{hl}^T x_{l-1}^k) \quad (3.34)$$

olarak yazılabilir. Burada $x_{i,l}^k$, $l-1$ gizli katmanında yer alan nöronların çıkışlarından oluşan vektördür. Eğer $l-1$ bir giriş katmanı ise bu durumda

$$x_{hi}^k = f_l(w_{hi}^T u^k) \quad (3.35)$$

olur. Burada u^k , o adımda uygulanmış giriş vektörüne karşılık gelir.



Şekil 29. Çok katmanlı ağ

Öğrenme kümesinden rasgele seçilen örneklerin ağ girişine uygulanarak elde edilen gerçek ağ çıkışı ile arzu edilen çıkış arasındaki farka bakarak bağlantı kuvvetlerinin değiştirilmesi ile öğrenme ilerler. Bu algoritma aşağıdaki gibi özetlenebilir:

3.5.5.1. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı İçin Geri Yayılm Öğrenme Algoritması

- İlk değer atama:

Bağlantı kuvvetlerine rasgele küçük değerler ver.

- Bir örnek uygula: bir u^k örnek giriş değerini girişe uygula ve arzu edilen çıkış y^k vektörünü bildir.

- İleri yayılım fazı: İlk gizli katmandan başlayarak çıkış katmanına kadar, $l=1, \dots, L$ için aşağıdakileri hesapla:

l katmanındaki her bir h nöronu için uyarım değeri:

Eğer $l-1$ giriş katmanı ise:

$$a_{hl}^k = \sum_{j=1}^N w_{jhl} u_{jk}^k \quad (3.36)$$

. Eğer $l-1$ bir gizli katman ise

$$a_{hl}^k = \sum_{j_{L-1}=1}^{N_{L-1}} w_{j_{L-1}hl} u_{j_{L-1}}^k \quad (3.37)$$

katmanındaki her bir h nöronu için çıkış değeri:

$$x_{hl}^k = f_l(a_{hl}^k) \quad (3.38)$$

Eğer l bir çıkış katmanı ise h_L yerine i_o kullan

- Çıkış hataları: Çıkış katmanındaki nöronlar için verilen hatayı hesapla

$$\delta_{i_o}^k = (y_{i_o}^k - x_{i_o}^k) f'_o(a_{i_o}^k) \quad (3.39)$$

Burada $f'(\cdot)$ çıkış fonksiyonunun türevidir.

- Geri yayılım fazı: Çıkış katmanında hesaplanan hatayı son gizli katmandan başlayarak ilk gizli katmana doğru ($l=L \dots 1$) aşağıdaki hata terimi denklemine göre hesapla

$$\delta_{hl}^k = f'_o(a_{i_o}^k) \sum_{l+1=1}^{N_{l+1}} \delta_{i_{(l+1)}}^k w_{hl i_{(l+1)}}^k \quad (3.40)$$

Burada eğer $l+1$ bir çıkış katmanı ise $i_{(l+1)}$, yerine i_o kullan.

- Bağlantı kuvvetlerini değiştir

Bağlantı kuvvetlerini çıkış katmanında

$$w_{hL_{io}}(t+1) = w_{hL_{io}}(t) + \eta \delta_{io}^k x_{hl}^k \quad (3.41)$$

Bağlantı kuvvetlerini gizli katmanda

$$w_{j_{l-1}h}(t+1) = w_{j_{l-1}h}(t) + \eta \delta_{hl}^k x_{j_{l-1}h}^k \quad (3.42)$$

denkleminde göre değiştirilir. Eğer l-1 giriş katmanı ise, $x_{j_{l-1}h}^k$ yerine u_j^k kullanılır

- Döngü: 1-5 adımlarını durma kriterine ulaşıncaya kadar uygula . Durma kriteri ise

$$\langle e^k \rangle = \left\langle \frac{1}{2} \sum_{io=1}^M (y_{io}^k - x_{io}^k)^2 \right\rangle \quad (3.43)$$


hata değerinin yeteri kadar küçük olması seçilir.

4. BULGULAR

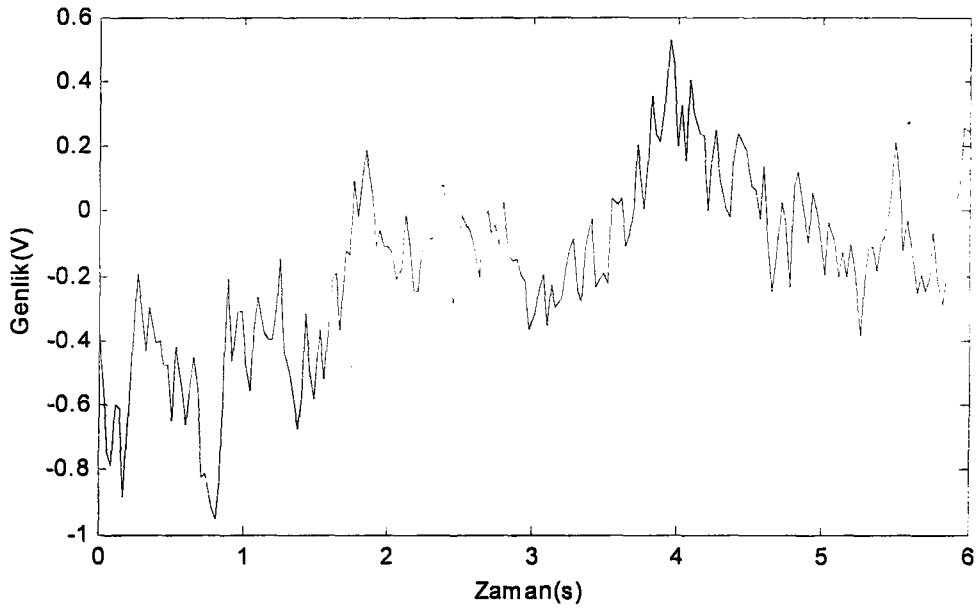
4.1. EEG Veri Setleri

Daha önceki bölümde anlatıldığı gibi EEG veri setlerinin bilgisayarda işlenebilmesi için kullanılan arabirim ünitesi ile örneklenmiş ve her bir EEG veri seti 6 saniyede 202 örnek olarak bilgisayara kayıt edilmiştir.

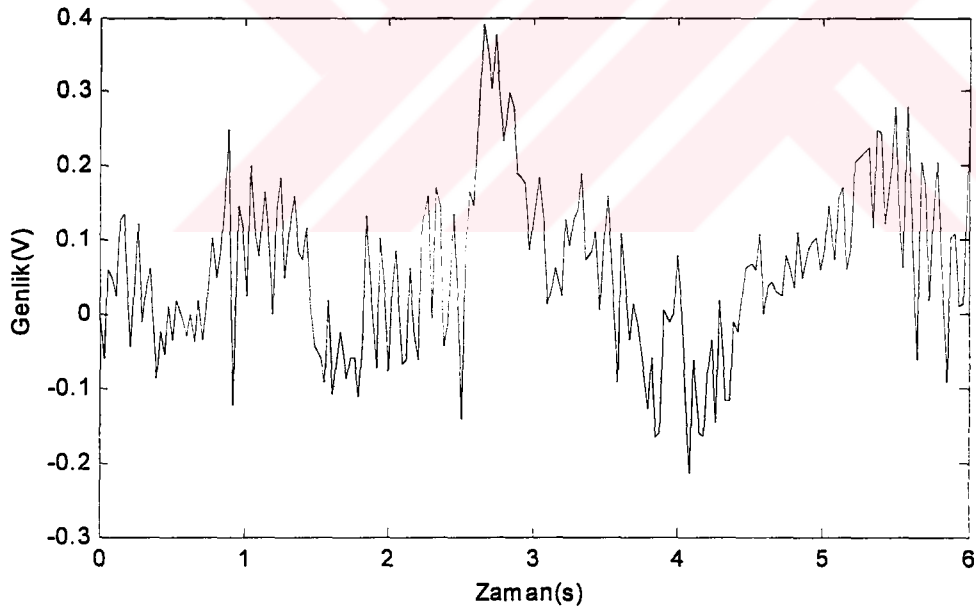
Kayıt edilen EEG veri setlerinden bir kaçı matlab programı kullanılarak Şekil 30-35'tekiler gibi çizilmiştir.




Şekil 30. Epileptik EEG




Şekil 31. Normal EEG




Şekil 32. Normal EEG



Şekil 33. Epileptik EEG



Şekil 34. Patolojik EEG



Şekil 35. Patolojik EEG

Yukarıda şekillerde kaydedilen çeşitli EEG dalga formları gösterilmiştir. Bu şekiller epileptik, normal ve patolojik durumları göstermektedir. Epileptik durumlardaki deşarjlar dalgaformunda bir pik ve frekansı diğer süreçlere oranla daha düşük olarak karşımıza çıkmaktadır. Bu tarz piklerin dalga formunda gözlenmesi esnasında yapılacak gözlem hatalarına dikkat etmemiz gerekmektedir. Bunun içinde teşhisin doğru yapılma oranı deneyimin fazlalığı ve iyi bir gözleme bağlı olarak artmaktadır.

Normal bireylerden alınmış EEG kayıtları incelendiği zaman alfa işaretlerinin dominant durumu kolaylıkla göze çarpmaktadır. Bunu gözlemek için doktorların yaptığı gibi bir saniyedeki dalga sayısını sayabilmenin yanı sıra işaret analiz teknikleri ile kolaylıkla bulunabilmektedir.

Patolojik dalgaların genlik ve frekansları çok çeşitlilik arz etmektedir. Bu dalgaların düşük frekanslı yüksek genlikli dalgalara sahip olmasının yanı sıra, α dalgasına da rastlamak mümkündür. Bu yüzden patolojik dalgaların da normal ve epileptik dalga formlarından ayırt edilmesi gerekmektedir.

Beyin işaretlerin kişiden kişiye değişmesinden dolayı bu tür işaretlerin sınıflandırılması yönünden bazı kriter değerlere dikkat edilmesi gerekir. Yani herhangi bir sağlıklı bireyden alınan EEG kaydıyla diğer bir bireyden alınan EEG kaydının tıpatıp aynı olması beklenmemelidir. Genetik özelliklerin, yaş durumunun ve bunun gibi bir çok nedenin etkin

olması sebebiyle, insanların beyin işaretlerinin frekans ve genlikleri değişiklik arz etmektedir. EEG kayıtları alınırken bu değişiklikler göz önünde tutulup, doğal karşılanmakta ve EEG kayıtlarındaki bu farklılıklardan ayrı olarak anomalilere dikkat edilmektedir.

Yukarıda gösterilen EEG kayıtları gözün kapalı olduğu ve zihnin boşaltıldığı yani dinlenim anlarında kayıt edilmiştir. Böylece EEG dalga formlarının kayıt edildiği süreçte alfa dalgalarının baskın olması doğal olarak beklenmektedir. Ancak alfa dalgasının baskınlığı ifadesinden sadece alfa dalgasının varlığı manası çıkarılmamalıdır. Yani EEG kaydında, daha önceki bölümlerde anlatılan beyin diğer alt frekans bantları da bulunabilmekte fakat bu süreçte alınan kriterin alfa dalgasının baskın olma durumuna dikkat edilmesi gerekmektedir. Aşağıda gösterilen şekiller incelendiği zaman sırasıyla z4 ve r2 EEG dalgalarının sağlıklı bireylerden alındığı göze çarpmaktadır. Bunun yanı sıra b9 ve b16 dalgalarında epileptik deşarjların karakteristik özelliklerini taşıyan düşük frekanslı yüksek genlikli dalgalar gözlenmektedir. Bunlara ilaveten b13 ve b11 EEG kayıtlarında normal beyin dalgalarının yanı sıra düşük frekanslı ve yüksek genlikli anormal dalga formları da gözlenmektedir.


4.2. EEG Veri Setlerine Dalgacık Dönüşümünün Uygulanması

Kaydedilen EEG dalga formları analizi için çeşitli işaret analiz metotları kullanılabilir. Bunlardan en kolay uygulanabilecek olanı herkesin bildiği Fourier transformudur. Bu dönüşüm metodu ile zaman domeninden frekans domenine geçip, işaretin frekans bileşenlerinin aldığı değerler görülebilir, fakat EEG işareti durağan olmadığından dolayı Fourier dönüşümü ve Fourier dönüşümünü esas alan bazı dönüşümleri kullanmak çok fazla yarar sağlamayacaktır. Bu yüzden işaretlerin frekans bileşenlerinin zamanda aldığı değerleri gösterebilen dalgacık dönüşümünün kullanılması özellikle zaman içerisinde epileptik deşarjların neden olduğu pikleri, yani düşük frekanslı yüksek genlikli dalgaların gözlenmesi açısından büyük yararlar sağlayacaktır.

Dalgacık dönüşümünün temelinde, bir bakıma frekansın tersi olan ağırlık parametresi ile işaretin tamamıyla frekans bileşenlerinin zaman içerisinde aldığı değerleri bulmak yatar. Yani Şekil 37-42'deki gibi EEG işareti δ , θ , α ve β alt frekans bantlarına ayrılmıştır.

EEG işaretlerinin dalgacık bileşenlerini analiz etmek için Daubechies dalgacıklarından db4 kullanılmıştır. EEG işaretleri alt ve üst frekans bantlarına ayrılmış daha sonrada sözünü ettiğimiz alt bantlarda kendilerinin alt ve üst bantlarına ayrılmıştır. Bu ayırma işlemi şekildeki gibi gösterilmiştir.

Burada görülen S işareti EEG işaretidir ve δ , θ , α ve β alt frekans bantları sırasıyla 0-4Hz, 4-8Hz 8-12Hz ve 12-16Hz bant genişliklerine sahiptir.



Şekil 36. EEG işaretlerinin dalgacıklarına ayrılması

Bu analiz işlemi yapmak üzere matlab komut penceresinde aşağıda gösterilen komutlar kullanılmıştır.

```
a=[0:(6/201):6];
```

```
y=b9+(0.0001*sin(360*32*a));
```

```
[c,l]=wavedec(y,4,'db4');
```

```
d4 = wrcoef('d',c,l,'db5',1);
```

```
a4 = wrcoef('a',c,l,'db5',1);
```

```
[c1,l1]=wavedec(d4,3,'db5');
```

```
d3 = wrcoef('d',c1,l1,'db5',1);
```

```
[c2,l2]=wavedec(a4,3,'db5');
```

```
d2 = wrcoef('d',c2,l2,'db5',1);
```

```
d1 = wrcoef('a',c2,l2,'db5',1);
```

```
[c3,l3]=wavedec(d1,3,'db4');
```

```
d1 = wrcoef('d',c3,l3,'db4',2);
```

```
d0 = wrcoef('d',c3,l3,'db4',3);
```

```
subplot(5,1,1);plot(a,b9);
```


```
subplot(5,1,2);plot(a,d0);
```

```
subplot(5,1,3);plot(a,d1);ylabel('Genlik(V)');
```


```
subplot(5,1,4);plot(a,d2);
```

```
subplot(5,1,5);plot(a,d3);xlabel('Zaman(s)');
```


Yukarıda verilen EEG kayıt örnekleri ve bu örneklerin dalgacıklarına ayrılmış halleri aşağıda Şekil 37-42' de gösterilmiştir. Bu şekillerde verilen EEG verileri ve frekans alt bantları yukarıdan aşağıya doğru a,b,c,d ve e olarak verilmiştir.




Şekil 37. a) Epileptik EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı




Şekil 38. a) Normal EEG b) δ dalgacıđı c) θ dalgacıđı d) α dalgacıđı e) β dalgacıđı




Şekil 39. a) Normal EEG b) δ dalgacıđı c) θ dalgacıđı d) α dalgacıđı e) β dalgacıđı



Şekil 40. a) Epileptik EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı




Şekil 41. a) Patolojik EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı



Şekil 42. a) Patolojik EEG b) δ dalgacıđı c) θ dalgacıđı d) α dalgacıđı e) β dalgacıđı

Yukarıdaki şekillerde ana işaret S olarak b9, b16, r2, z4, b11 ve b13 EEG kayıtları verilmiştir ve bu işaretlere ait δ , θ , α ve β frekans bantları gösterilmektedir. Dalgacık dönüşümünde kullanılan dalgacık Daubachies dalgacık prototiplerinden db4'tür (Şekil 43).



Şekil 43. db4 dalgacığ

BATTLE-LEMARİE ortonormal ağırlık fonksiyonları, $m \geq 2$ için m . Dereceden cardinal B-spline dalgacıklarını ($N_m(t)$) ortonormalize ederek elde etmiştir. Fakat $E_{N_m}(z)$ paydadaki varlığından dolayı $[g_o[k]]$ dizisi sonsuz uzunlukta olmaktadır.

Polinomun (Laurent) derecesini sonlu uzunlukta tutup ortonormaliteyi elde etmek için, Daubechies ağırlıklandırma fonksiyonu için iki indisli sembol $\phi_{D,m}$ ' yi düşünmüştür.

$$G_0(z) = \left(\frac{1+z}{2} \right)^m S(z) \quad (4.1)$$

olur ki burada $S(z) \in \pi_{m-1}$ dir. Bununla birlikte $S(z)$ yi bulmamız gerekmektedir. Bunun için $G_0(1)=1$ olması nedeniyle $S(1)=1$ olması gerekir. Buna ilaveten $S(-1) \neq 0$ olmasını isteriz. çünkü eğer $S(-1)=0$ olursa , $z+1$ $S(z)$ nin bir çarpımı olur ve dikkate alınmayabilir. Şimdi yukarıdaki eşitlikte verilen $G_0(z)$ ortogonalite koşulunu sağlamalıdır. Yani

$$|G_0(z)|^2 + |G_0(-z)|^2 = 1, \quad z = e^{j\omega/2} \quad (4.2)$$

$$\cos^{2m} \frac{\omega}{4} |S(z)|^2 + \sin^{2m} \frac{\omega}{4} |S(-z)|^2 = 1 \quad (4.3)$$

Burada

$$x = \sin^2 \frac{\omega}{4} \quad (4.4)$$

ve

$$f(x) = |S(z)|^2 \quad (4.5)$$

olduğu kabul edilirse yukarıdaki eşitlik

$$(1-x)^m f(x) + x^m f(1-x) = 1 \quad (4.6)$$

$$f(x) = (1-x)^m [1-x^m f(1-x)] = \sum_{k=0}^{m-1} \binom{m+k-1}{k} x^k + R_m(x) \quad (4.7)$$

$$R_m(x) = \sum_{k=0}^{m-1} \binom{m+k-1}{k} x^k + (-x)^m f(1-x) \sum_{k=0}^{\infty} \binom{m+k-1}{k} x^k \quad (4.8)$$

$f(x)$ m. Dereceden bir polinom olduğu için, $R_m(x) \equiv 0$ dir. Böylece aşağıdaki eşitliği elde etmiş oluruz.

$$|S(z)|^2 = \sum_{k=0}^{m-l} \binom{m+k-l}{k} \sin^{2k} \frac{\omega}{4}, \quad z = e^{-j\omega/2} \quad (4.9)$$

yukarıdaki polinom şu hale dönüştürülebilir

$$|S(z)|^2 = \frac{a_0}{2} + \sum_{k=1}^{m-l} a_k \cos \frac{k\omega}{2} \quad (4.10)$$

ki burada

$$a_k = (-1)^k \sum_{n=0}^{m-k-l} \frac{1}{2^{2(k+n)-1}} \binom{2(k+n)}{n} \binom{m+k+n-l}{k+n} \quad (4.11)$$

Buna ilaveten $S(z)$ nin $|S(z)|^2$ den çıkarılması gerekmektedir.

Riesz' in önermesine göre, kosinüs serileri ile ilgili $a_0, \dots, a_N \in \mathcal{R}$ ve $a_N \neq 0$ olmak kaydıyla aşağıdaki gibi öyle bir polinom vardır ki

$$\hat{f}(\omega) = \frac{a_0}{2} + \sum_{k=1}^N a_k \cos k\omega \quad (4.12)$$

$$g(z) = \sum_{k=0}^N b_k z^k \quad (4.13)$$

Burada $a_0, \dots, a_N \in \mathcal{R}$ ve;

$$|g(z)|^2 = \hat{f}(\omega) \quad z = e^{-j\omega} \quad (4.14)$$

dir.

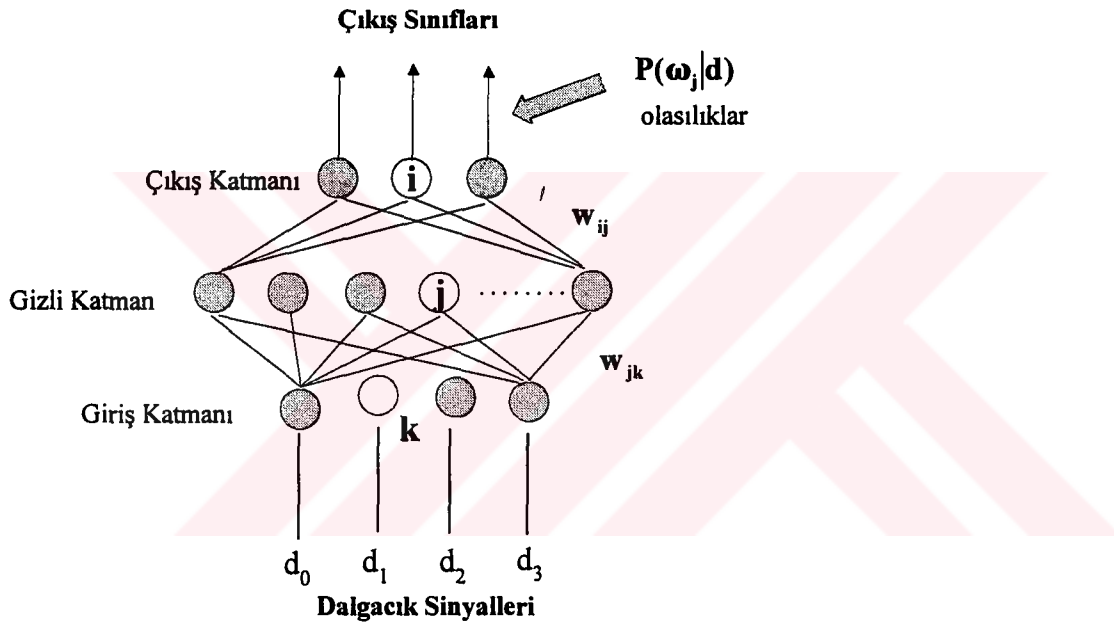
Riesz önerisini uygulayarak, $S(z)$ için aşağıdaki yazılış formunu elde etmek kolaydır

$$S(z) = C \prod_{k=1}^K (z - r_k) \prod_{l=1}^L (z - z_l)(z - \bar{z}_l) \quad K + 2L = m - 1 \quad (4.15)$$

Burada $\{r_k\}$ sıfır olmayan gerçekte kökler, $\{z_i\}$, $z^{m-1}|S(z)|^2$ nin birim çember içinde kalan kompleks kökleri ve $C, S(1)=1$ durumunu sağlayan bir sabittir[16].

4.3. Dalgacık Dönüşümü Sonrası Elde Edilen Verilerin Yapay Sinir Ağına Uygulanması

Dalgacık Dönüşümü sonrasında elde edilen δ , θ , α ve β dalgalarına ilişkin sonuçlar yapay sinir ağını eğitmek üzere giriş verileri olarak kullanılmıştır. Şekil 44'te görülen yapay sinir ağı Matlab isimli paket program ile oluşturulmuştur.



Şekil 44. Oluşturulacak yapay sinir ağının şekli

4.3.1. Uygulama Sonuçları

Bu çalışmada kullanılan yapay sinir ağının eğitim karakteristikleri aşağıdaki gibidir.

4.3.2. Yapısı

Katman Sayısı: 3 Bunlar giriş- gizli-çıkış katmanlarıdır.

Katmanlardaki nöron sayıları: (4 x 202) - 15 - 3 (giriş-gizli-çıkış katmanları için)

Eğitim Parametreleri

Adaptif Öğrenme Katsayısı: 0.0005

Momentum Katsayısı: 0.95

Hata-kareleri-toplamı: 0.0005

Hata geri yayımlı yapay sinir ağının eğitim sürecindeki öğrenme iterasyonlarına göre sistem hatasının değişimi aşağıdaki şekilde gösterilmiştir. Ağın eğitimi süresince herhangi bir kararsızlık veya pürüz olmamıştır. Bu seçilen eğitim parametrelerinin güvenilirliğini göstermektedir

İkinci aşama olarak eğitilen ağ farklı sınıflardaki EEG dalgacık işaretleri ile eğitilmiştir. Bu testin sonucunda gözlemlenen yapay sinir ağının çıkış vektörlerine göre hastalığı teşhis etmek mümkün olmaktadır.

4.3.3. Oluşturulacak Yapay Sinir Ağı İçin Gerekli Program

Yapay sinir ağının eğitilmesi için Matlab programında yazılmış olan program aşağıdaki gibidir.

% P: giriş vektörü, T :hedef vektör

load b9.mat;P=[d0;d1;d2;d3]; e1=P; %epileptik

load b16.mat;P=[d0;d1;d2;d3]; e2=P; %epileptik0

load r1.mat;P=[d0;d1;d2;d3]; s1=P; %sağlam

load r2.mat;P=[d0;d1;d2;d3]; s2=P; %sağlam

load r4.mat;P=[d0;d1;d2;d3]; s3=P; %sağlam

```
load b13.mat;P=[d0;d1;d2;d3]; p1=P; %patolojik
```

```
load b12.mat;P=[d0;d1;d2;d3]; p2=P; %patolojik
```

```
load b11.mat;P=[d0;d1;d2;d3]; p3=P; %patolojik
```

```
P=[e1 e2 s1 s2 s3 p1 p2 p3];
```

```
T=[1 0 0;1 0 0;0 1 0;0 1 0;0 1 0;0 0 1;0 0 1;0 0 1];
```

```
T=T';
```

```
% BP Ağının Kurulması
```

```
[R,Q]=size(P); % R : giriş sayısı, Q : giriş örnek sayısı
```

```
S1=15; % S1= 1. ara katmandaki noron sayısı
```

```
S2=10; % S2= 2. ara katmandaki noron sayısı
```

```
[S3,Q]=size(T); % S3=çıkış katmandaki noron sayısı
```

```
[w1,b1]=nwtan(S1,R);
```

```
[w2,b2]=nwtan(S2,S1);
```

```
[w3,b3]=nwtan(S3,S2);
```

```
% Eğitim Parametreleri
```

```
df=50; % tekrar sayısı
```

```
sse=0.0005; % minimum hata
```

```
mitr=20000; % maksimum iterasyon
```

```
lr=0.0005; % öğrenme oranı (0.01,.....,1)
```

```
lr_inc=1.05; % öğrenme oranının artırımı
```

```
lr_dec=0.7; % öğrenme oranının azaltımı
```

```
mr=0.95; % momentum katsayısı (0....1)
```

```
er=1.04; % hata oranı -adaptif lr için gerekli
```

```
tp=[df,mitr,sse,lr,lr_inc,lr_dec,mr.er];
```

```
%Eğitim Yapılıyor
```

```
[w1,b1,w2,b2,w3,b3,epochs
```

```
error]=trainbpx(w1,b1,'tansig',w2,b2,'tansig',w3,b3,'tansig',P,T,tp);
```

```
save data.mat w1 b1 w2 b2 w3 b3
```

```
% Test etme
```

```
%load data.mat;
```

```
%Pt=e;out=simuff(Pt,w1,b1,'tansig',w2,b2,'tansig',w3,b3,'tansig');
```

```
TRAINBPX: 0/20000 epochs, lr = 0.0005, SSE = 18.3668.
```

```
TRAINBPX: 50/20000 epochs, lr = 0.0057337, SSE = 13.1743.
```

```
TRAINBPX: 100/20000 epochs, lr = 0.0366124, SSE = 3.55521.
```

```
TRAINBPX: 150/20000 epochs, lr = 0.0368592, SSE = 0.0562617.
```

```
TRAINBPX: 200/20000 epochs, lr = 0.0242849, SSE = 0.0299022.
```

```
TRAINBPX: 250/20000 epochs, lr = 0.240566, SSE = 0.0130908.
```

TRAINBPX: 300/20000 epochs, lr = 0.0202495, SSE = 0.00315068.

TRAINBPX: 350/20000 epochs, lr = 0.0583447, SSE = 0.00288481.

TRAINBPX: 400/20000 epochs, lr = 0.669062, SSE = 0.00226165.

TRAINBPX: 450/20000 epochs, lr = 0.0230496, SSE = 0.00181814.

TRAINBPX: 500/20000 epochs, lr = 0.10983, SSE = 0.00165702.

TRAINBPX: 550/20000 epochs, lr = 1.25946, SSE = 0.00127083.

TRAINBPX: 600/20000 epochs, lr = 0.0249875, SSE = 0.00115551.

TRAINBPX: 650/20000 epochs, lr = 0.213822, SSE = 0.0011136.

TRAINBPX: 700/20000 epochs, lr = 0.0404962, SSE = 0.00093059.

TRAINBPX: 750/20000 epochs, lr = 0.0470372, SSE = 0.000899084.

TRAINBPX: 800/20000 epochs, lr = 0.347698, SSE = 0.000850461.

TRAINBPX: 850/20000 epochs, lr = 0.0152878, SSE = 0.000799354.

TRAINBPX: 900/20000 epochs, lr = 0.0629267, SSE = 0.000731804.

TRAINBPX: 950/20000 epochs, lr = 0.538473, SSE = 0.00068739.

TRAINBPX:1000/20000 epochs, lr = 0.0204522, SSE = 0.000628829.

TRAINBPX:1050/20000 epochs, lr = 0.0841839, SSE = 0.000619939.

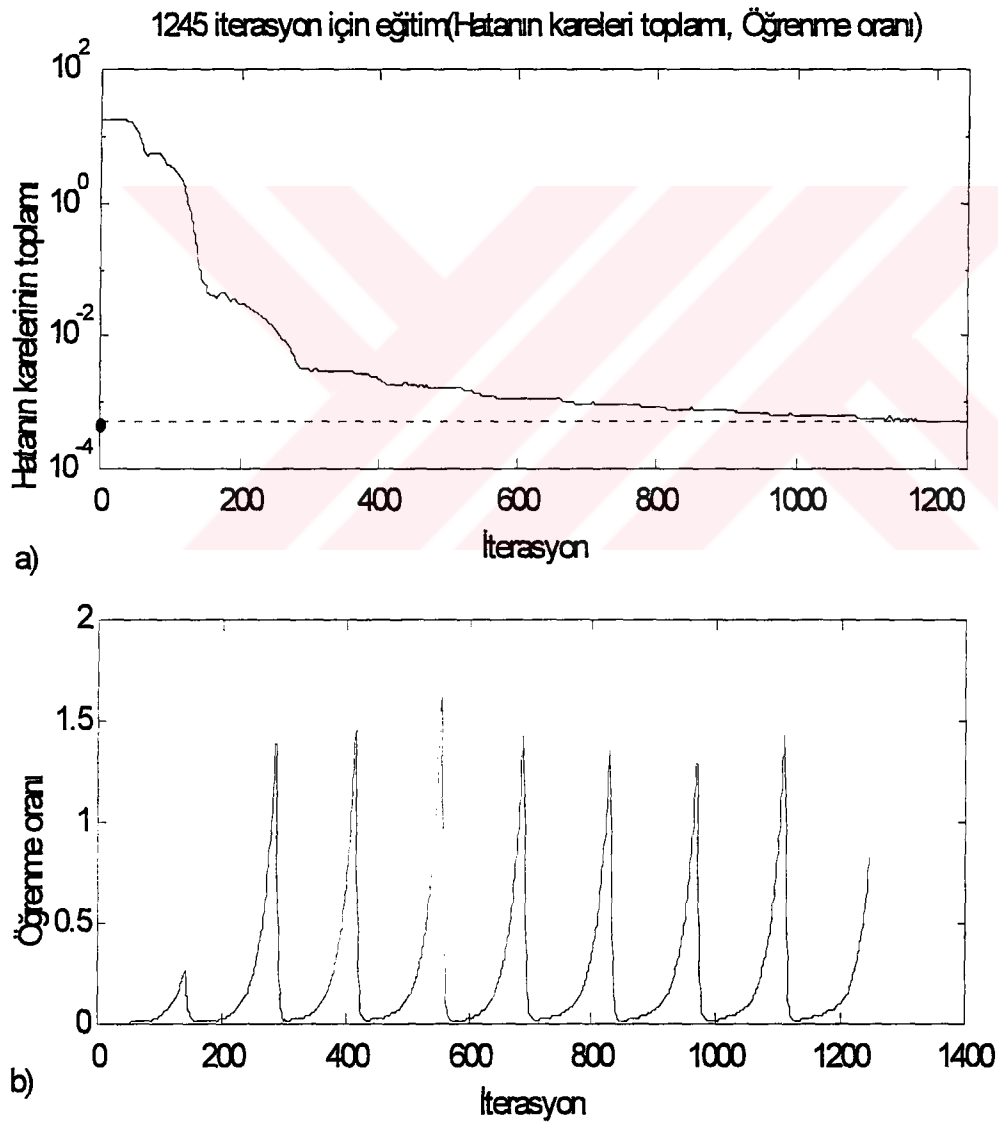
TRAINBPX: 1100/20000 epochs, lr = 0.9194, SSE = 0.000571425.

TRAINBPX: 1150/20000 epochs, lr = 0.0287291, SSE = 0.000540502.

TRAINBPX: 1200/20000 epochs, lr = 0.102151, SSE = 0.000532361.

TRAINBPX: 1245/20000 epochs, lr = 0.832499, SSE = 0.000499074.


Yapay sinir ağının eğitimi boyunca, hatanın ve öğrenme oranının iterasyon sayısına göre değişimi aşağıda Şekil 45'te verilmiştir.




Şekil 45. Eğitim boyunca meydana gelen hatanın karelerinin toplamı(a) ve öğrenme oranının(b) iterasyona göre değişimi

Burada eğitilen yapay sinir ağı modeli daha sonra, çeşitli tipte EEG kayıtları alınıp teste tabi tutulmuştur. Aşağıdaki şekillerde test işaretleri gösterilmiştir. Bu test işaretlerinden ilki epilepsi hastasına, daha sonraki dördü sağlıklı insanlara ve sonuncusu da patolojik bir hastaya ait EEG işaretleridir (Şekil 46-51). Bu şekiller incelendiği zaman patolojik olan EEG verisinde α frekans bandının yanı sıra δ ve θ bandına ait frekans bileşenleri görülmektedir. Normal EEG verilerinde yine hakim frekans α bandıdır. Epileptik EEG verisi incelendiği zaman keskin bir dalga göze çarpmaktadır ve burada bu keskin dalganın sahip olduğu frekans düşüktür. Ayrıca epileptik EEG verisi için bir saniyedeki pik sayısı sayıldığı zaman 4-5 arasında çıkmaktadır. Yani burada pik saymaya bağlı olarak çıkan hakim frekans 4-5 Hz'dir.


Geliştirilen yapay sinir ağının, bu EEG işaretleri ile test edilmesinden elde edilen sonuçlar tablo 1'de gösterilmiştir. Bu sonuçlardan çıkarılan en önemlisi ağın test işaretlerini çok az bir hata yapma olasılığı ile tanımasıdır. Bunu şu şekilde açıklayabiliriz. Eğer test işareti olarak z1.mat.'ı alıyorsak, ağımız bunu %96'lık bir doğruluk oranı ile tanıyacaktır. Bu da ağın bu şekildeki işaretlere benzer EEG kayıtlarına sahip 100 hastadan 96'sının durumunu doğru olarak ve sağlık durumlarının sağlam olduğunu teşhis edeceği anlamına gelmektedir. Buna ilaveten ağımız bu tabloya göre uygulanan test verilerinden epileptik olanı % 99, patolojik olanı % 94 ve sağlıklı olanları % 94, % 97, %97, % 99 doğruluk oranları ile tanıyacaktır.




Şekil 46. Patolojik EEG test verisi




Şekil 47. Normal EEG test verisi




Şekil 48. Normal EEG test verisi



Şekil 49. Epileptik EEG test verisi



Şekil 50. Normal EEG test verisi



Şekil 51. Normal EEG test verisi

Sinyaller	Teşhis	Tanıma Oranı (%)
b1.mat	Epilepsi	99
z1.mat	Sağlıklı	96
z2.mat	Sağlıklı	99
z3.mat	Sağlıklı	97
z4.mat	Sağlıklı	97
z6.mat	Patolojik	94

Tablo 1. Eğitilen yapay sinir ağının EEG test kayıtlarını tanıma oranı

5. SONUÇLAR VE TARTIŞMA

Bu çalışmada çoğunlukla alfa dalgalarını içeren EEG verileri kullanılmıştır. Bununla birlikte düşük frekans bileşenleri içeren EEG dalgaları da kullanılmıştır.

EEG verilerinin içerdiği farklı frekans bileşenlerinin kestirimi için işaret analiz metotlarından biri olan dalgacık dönüşümü metodu kullanılmıştır. Dalgacık analizi metodunun kullanımıyla birlikte yalnızca işaretin içerdiği spektral bileşenler değil, ayrıca bu spektral bileşenlerin zaman içerisinde aldığı değerlerde gözlenmiştir. Bu da özellikle epilepsi hastalarında meydana gelen epileptik deşarjların daha iyi yorumlanmasını kolaylaştırmıştır.

Spektral analiz metotlarından biri olan Fourier dönüşümü ile işaretler, içerdikleri spektral bileşenlerine ayrılabilir. Fakat Fourier dönüşümü ile işaretle meydana gelen anlık değişimler gözden kaçmaktadır. Fourier dönüşümünün bu eksikliğini gidermek için ya kısa süreli FFT dönüşümü veya bu çalışmada kullanılan dalgacık dönüşümünü kullanmak gerekmektedir.

Dalgacık dönüşümünün kullanımıyla birlikte işaret eksenler zaman frekans ve genlik olmak üzere üç boyutlu bir grafikte gösterilebilmektedirler. Yani bu ifade işaretin hangi anda hangi frekans ve genlik değerinde olduğunu bilmesi anlamına gelmektedir.

Hastalığı teşhis eden kişilerin doktorlar olduğunu düşünürsek, bunların çoğunluğunun karmaşık olan EEG işaretlerini yorumlamaları zor olduğundan, bu yorumu yapacak uzman bir yapay sinir ağı geliştirilerek hastalık teşhisi için kolaylık sağlamak istenmiştir. Ayrıca doktorların bu tür çalışmalardan faydalanması için görselliğin sağlanması gerekmektedir. Bu görselliğin sağlanması için yapay sinir ağı modeli kullanmak en mantıklı yollardan biridir. Böylece bu gibi çalışmaların olası pratik uygulamalarına muhatap olacak doktorlar, sadece bu sistemin çıkış nöronlarına bağlı herhangi bir çıkış ünitesiyle (monitör, led gösterge, yazıcı vs.) hastanın o anki sağlık koşullarına bağlı olan EEG kaydının sonuçlarını basit bir şekilde görecektir.

Bu sistemde geliştirilen yapay sinir ağı modeli başarı oranı, çalışmanın bulgular bölümünde de görüldüğü gibi yüksek çıkmıştır. Bu ifade, sistemin analizini yaptığı kişinin sağlık durumunu çok küçük bir hata yüzdesi ile tanıyacağı anlamına gelmektedir.

Yapay sinir ağlarında daha iyi bir sınıflandırma verilerin fazlalığı ile doğru orantılı olarak artmaktadır. Yani bu çalışmadaki sıkıntılardan biri de sağlık koşullarını gösteren verilerin azlığı idi. Bu problemde yapay sinir ağına ilişkin parametrelerin uygun çözümü ile bir ölçüde aşılmıştır.

Özellikle epilepsi hastalığında , epileptik deşarjların tanımlanması zor olmaktadır. Çünkü bir çok durumda epileptik deşarjlara benzeyen dalga formları meydana gelmektedir. Bu yüzden epilepsi hastalığı teşhisini koyacak doktorların iyi bir gözlemci ve deneyimlerinin fazla olması gerekir.

Sonuç olarak bu çalışmanın daha fazla veri ile yapılacak iyileştirilmiş halinin pratik uygulaması epilepsi teşhisi koymada doktorlar için faydalı olacaktır. Böylece bu tür sistemler rutin olarak kullanıldığında uzman hekimi olmayan hastanelerde EEG ve benzeri işaretlerin kestirimi için direk olarak kullanılabilir.



6. KAYNAKLAR

- [1] AKIN,M. , KIYMIK, M.K ., ARSERİM, M.A. , TÜRKOĞLU, İ., Separation of Brain Signals Using FFT and Neural Networks, Biyomut 2000,Istanbul, Turkey
- [2] BİLİR, E., Beyin Elektriksel Faaliyetinde Meydana Gelen Rahatsızlıklar, Beyin dinamiği multidisipliner lisans üstü yaz okulu ders notları, Diyarbakır, Temmuz 1999
- [3] ZURADA, M.J., Introduction to Artificial Neural Systems, New York. West Publishing Company, 1992.
- [4] COOPER, R., OSSELTON,J.W., SHAW, J.,C., EEG Technology, 1969, Butterworth & Co. (Publishers) Ltd.
- [5] AKIN, M., Uyarılmış Beyin Potansiyellerinin Spektral Analiz Yöntemleri İle İncelenmesi, Doktora tezi, E.Ü. 1995
- [6] MİSİTİ, M., MİSİTİ, Y., OPPENHEİM, G., POGGİ, J.M., Wavelet Toolbox Users Guide, COPYRIGHT 1996 - 1997 by The MathWorks, Inc.
- [7] SHIMADA, T., SHIINA, T., Detection of Characteristic Waves of Sleep EEG by Neural Network Analysis, Biomedical Engineering, IEEE Transactions on , Volume: 47 Issue: 3 , March 2000 Page(s): 369-379
- [8] HAZARIKA, N., Classification of EEG signals using the wavelet transform, May 1997, Signal Processing [H.W. Wilson - AST], Vol. 59, ISS: 1; pg. 61
- [9] MEHTA, S.V., KOSER, R.W., VENZİALE, P.J.,Wavelet analysis as a potential tool for seizure detection, Time-Frequency and Time-Scale Analysis, 1994., Proceedings of the IEEE-SP International Symposium on , 1994 Page(s): 584 -587
- [10] REUTER, M., Analysing epileptic events online by neural nets, special preprocessing methods included , Intelligent Control and Automation, 2000. Proceedings of the 3rd World Congress on, Volume: 2, 2000, Page(s): 919 -924 vol.2

[11] GEVA, A.B., KEREM, D.H., Forecasting generalized epileptic seizures from the EEG signal by wavelet analysis and dynamic unsupervised fuzzy clustering, Oct. 1998 , Biomedical Engineering. IEEE Transactions on , Volume: 45 Issue: 10 , Page(s): 1205 -1216

[12] TÜKEL, K., Klinik Elektroansefalografi, İstanbul 1980

[13] CROMWELL, L., Weibell, F.J., Pfeiffer, E.A., Biomedical Instrumentation and Measurements 1980 by Prentice Hall International, Inc

[14] AKIN, M., KIYMIK, M.K., Beyin işaretlerinin izgel çözümlenmesi için gerekli donanım ve yazılımın gerçekleştirilmesi, İşaret işleme ve bildiriler kurultayı bildiriler kitabı, 1995

[15] HALICI, U., Yapay sinir ağları, Beyin dinamiği multidisipliner lisans üstü yaz okulu ders notları, Diyarbakır, Temmuz 1999

[16] GOSWAMI, J., CHAN, A., Fundamentals of Wavelets, 1999, John Wiley & Sons Inc.,

[17] BIN ZHU, MICHELI-TZANAKU, E., Nonstationary speech analysis using neural prediction, Jan./Feb.2000, IEEE Trans. Eng. in Med. and Biology , pp.102-105,

[18] DEMUTH, H., BEALE, M., Neural Network Toolbox User's Guide, COPYRIGHT 1992 - 1998 by The MathWorks, Inc.

[19] FAUSETT, L., Fundamentals of Neural Networks, Prentice Hall International, Inc, 1994

[20] BISHOP, C. M., Neural Networks for Pattern Recognition, *Clarendon Press*, Oxford, 1996.

[21] DUDA, R.O., HART, P.E., Pattern Classification and Scene Analysis. Stanford Research Institute, 1989.

[22] AKIN, M., KIYMIK, M.K., Application of Periodogram and AR Spectral Analysis to EEG Signals, 2000, Journal of Medical Systems, Vol.24 No.4,

[23] SIMPSON, P., Artificial Neural Systems, Pergamon Press Company, New York, 1990.

al of Science Institute, 1996, p.147-158.

[24] DAYHOFF, J.E., Neural Network Architectures, Van Nostrand Reinhold, New York, 1990.

[25] PEHLIVAN, F., Biyofizik, Ankara 1997, Atlas kitabevi



ŞEKİLLER TABLOSU

Şekil 1. Gerçekleştirilen sistemin donanımı	11
Şekil 2. Fourier dönüşümü.....	12
Şekil 3. Kısa Zamanlı Fourier Dönüşümü	12
Şekil 4. İşaretin zaman, frekans tabanlı ve çeşitli şekillerde alınan dönüşümlerinin gösterilmesi.....	13
Şekil 5. Bir sinüs dalgası ve bir ana dalgacık prototipi	13
Şekil 6. Ana dalgacığın ağırlıklandırılması	15
Şekil 7. Ana dalgacığın kaydırılması.....	15
Şekil 8. Belirlenen C değerine göre işaretle dalgacığın karşılaştırılması	16
Şekil 9. Dalgacığın işaretin kesitleriyle karşılaştırılması	16
Şekil 10. C değerinin değiştirilip, dalgacık ile işaretin tekrar karşılaştırılması.....	16
Şekil 11. Farklı ağırlıklara göre işaretin dalgacık değerlerinin bulunması.....	17
Şekil 12. İşaretin düşük ve yüksek frekanslı bileşenlerine ayrılması	18
Şekil 13. Dalgacık ayrıştırma ağacı	19
Şekil 14. Bir işaretin yaklaşım ve detaylarına ayrılması	19
Şekil 15. Dalgacık paket analizlerinde ayrıştırma	20
Şekil 16. Dalgacık paket ayrıştırma ağacı	21
Şekil 17. Biyolojik bir nöronun yapısı.....	22
Şekil 18. Nöronlarda iletim.....	23
Şekil 19. Yapay nöron	24
Şekil 20. Uyarım fonksiyonları.....	26
Şekil 21. Mantık fonksiyonlarının yapay nöronlarla gösterimi	27
Şekil 22. a) çok katmanlı ve ileri beslemeli ağ b) katmansız ve geri beslemeli ağ	30
Şekil 23. Perseptron	32
Şekil 24. Perseptron tarafından belirlenen hiper-düzlem giriş uzayını iki karar bölgesine ayırır. İki boyutlu uzayda bu hiper-düzlem bir doğru denklemine iner.	32
Şekil 25. Perseptron yakınsaması.....	34
Şekil 26 (a) üst üste dağılım (b) doğrusal ayrılmaz dağılım.....	35
Şekil 27. Tek veya çok katmanlı perseptron tarafından oluşturulabilen karar bölgeleri	35
Şekil 28. Geri yayılım algoritması için nöron çıkış fonksiyonu.....	36
Şekil 29. Çok katmanlı ağ.....	37
Şekil 30. Epileptik EEG.....	40
Şekil 31. Normal EEG	41
Şekil 32. Normal EEG	41

Şekil 33. Epileptik EEG.....	42
Şekil 34. Patolojik EEG.....	42
Şekil 35. Patolojik EEG.....	43
Şekil 36. EEG işaretlerinin dalgacıklarına ayrılması.....	45
Şekil 37. a) Epileptik EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı	47
Şekil 38. a) Normal EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı.....	48
Şekil 39. a)Normal EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı.....	49
Şekil 40. a) Epileptik EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı	50
Şekil 41. a) Patolojik EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı	51
Şekil 42. a) Patolojik EEG b) δ dalgacığı c) θ dalgacığı d) α dalgacığı e) β dalgacığı	52
Şekil 43. db4 dalgacığı	53
Şekil 44. Oluşturulacak yapay sinir ağının şekli	56
Şekil 45. Eğitim boyunca meydana gelen hatanın karelerinin toplamı(a) ve öğrenme oranının(b) iterasyona göre değişimi	61
Şekil 46. Patolojik EEG test verisi	62
Şekil 47. Normal EEG test verisi.....	63
Şekil 48. Normal EEG test verisi.....	63
Şekil 49. Epileptik EEG test verisi	64
Şekil 50. Normal EEG test verisi.....	64
Şekil 51. Normal EEG test verisi.....	65

YAZARIN ÖZGEÇMİŐİ

Muhammet Ali ARSERİM 1975 yılında Őanlıurfa'nın Siverek ilçesinde doğdu. 1986 yılında Elazığ Atatürk İlkokulu'ndan mezun oldu. Aynı yıl Elazığ Anadolu Lisesi'ne kayıt oldu ve 1993 yılında bu okuldan mezun oldu. Yazar 1993 yılında Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Elektrik-Elektronik Mühendisliđi Bölümünü kazandı ve 1997 yılında bu okuldan mezun olarak Elektrik-Elektronik Mühendisi diplomasını aldı.

Muhammet Ali ARSERİM 1998 yılında Dicle Üniversitesi Mühendislik-Mimarlık Fakültesi Elektrik-Elektronik Mühendisliđi Bölümü'nde Arařtırma Görevlisi olarak göreve başladı. Halen adı geçen kurumda Arařtırma Görevlisi olarak çalışmaktadır.

