T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOPPLER İŞARETLERİNİN DALGACIK DÖNÜŞÜMÜ VE FRAKTAL BOYUT KULLANARAK YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Esra YILDIZ

06231104

Anabilim Dalı: Elektronik ve Bilgisayar Eğitimi

Programı: Bilgisayar Sistemleri Eğitimi

Tez Danışmanı: Doç. Dr. İbrahim TÜRKOĞLU

Tezin Enstitüye Verildiği Tarih:07/12/2009

ARALIK-2009

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOPPLER İŞARETLERİNİN DALGACIK DÖNÜŞÜMÜ VE FRAKTAL BOYUT KULLANARAK YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Esra YILDIZ

06231104

Tezin Enstitüye Verildiği Tarih :07/12/2009
Tezin Savunulduğu Tarih :28/12/2009

Tez Danışmanı : **Doç. Dr. İbrahim TÜRKOĞLU (F.Ü)**
Diğer Jüri Üyeleri : **Prof. Dr. Asaf VAROL (F.Ü)**
Doç. Dr. Mehmet KAYA (F.Ü)

ARALIK - 2009

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOPPLER İŞARETLERİNİN DALGACIK DÖNÜŞÜMÜ VE FRAKTAL BOYUT KULLANARAK YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Esra YILDIZ

Anabilim Dalı: Elektronik ve Bilgisayar Eğitimi

Programı: Bilgisayar Sistemleri Eğitimi

ARALIK - 2009

ÖNSÖZ

Bu tez çalışmam boyunca, ilgi ve yardımlarını esirgemeyen danışmanım sayın Doç. Dr. İbrahim TÜRKOĞLU'na, tezin programlama aşamasında yardımlarını esirgemeyen sayın Yrd. Doç. Dr. Engin AVCI ve Yrd. Doç. Dr. Abdulkadir ŞENGÜR hocalarıma, eğitim hayatım boyunca beni sabır ve özveri ile destekleyen babama teşekkür ve şükranlarımı sunarım.

Esra YILDIZ

ELAZIĞ-2009

İÇİNDEKİLER

Sayfa No

ÖNSÖZ I
İÇİNDEKİLER II
ÖZET IV
SUMMARY V
ŞEKİLLER LİSTESİ VI
TABLOLAR LİSTESİ IX
SİMGELER LİSTESİ X
SEMBOLLER LİSTESİ XI
KISALTMALAR LİSTESİ XII
1. GİRİŞ 1
2. DALGACIK DÖNÜŞÜMÜ
2.1. İşaret İşleme 6
2.2. Dalgacık Dönüşümü 7
2.3. Dalgacık Dönüşümü Türleri 11
2.3.1. Sürekli Dalgacık Dönüşümü 11
2.3.2. Ayrık Dalgacık Dönüşümü 13
2.4. Dalgacık Çeşitleri 15
2.5. Filtreleme 21
2.6. Biyomedikal Alanında Dalgacık Dönüşümü Uygulamaları 23
3. FRAKTAL ANALİZ
3.1. Fraktallerin Tanımı 25
3.2. Fraktal Geometri 26
3.3. Fraktallerin Günlük Hayatta Kullanımı 31
3.4. Fraktal Boyut 36
4. YAPAY SİNİR AĞLARI
4.1. Biyolojik Nöron ve Yapay Sinir Hücresi 40
4.2. Yapay Sinir Ağlarının Genel Yapısı 41
4.3. Yapay Sinir Ağ Sınıfları 44
4.3.1. Eğiticisiz Öğrenme 44
4.3.2. Eğiticili Öğrenme 46
4.3.3 Takviyeli Öğrenme 59

5. DOPPLER KALP SES İŞARETLERİNİN SINIFLANDIRILMASI
5.1. İşaretin Elde Edilmesi 61
5.2. Ön İşlem Süreci 63
5.3. Özellik Çıkarma 67
5.4. Sınıflandırma 70
6. SONUÇ VE DEĞERLENDİRME 76
KAYNAKLAR 77
ÖZGEÇMİŞ 84

ÖZET

Son zamanlarda dolaşım sisteminde çeşitli fonksiyon bozukluklarına, damar tıkanıklığı, damar daralması ve genişlemesine oldukça sık rastlanmaktadır. Bu tür problemler sonucunda ciddi rahatsızlıklar ortaya çıkmakta ve kan akışı problemleri ölüm sebebi olabilmektedir. Bu tür ölümcül vakaları ortadan kaldırmak amacıyla, rahatsız olduğu düşünülen vücut bölgesinin analiz edilmesine dayanan Doppler Ultrason Tekniği kullanılmakta ve hastaya herhangi bir cerrahi müdahalede bulunulmamaktadır.

Bu tez çalışmasında, doppler kalp işaretlerinin sınıflandırılması için örüntü tanıma temelli yeni bir uygulama yaklaşımı önerilmiştir. Önerilen yöntemde özellik çıkarma sürecinde dalgacık dönüşümü ve fraktal boyut hesaplaması, sınıflama sürecinde ise geri yayılım yapay sinir ağı kullanılmıştır. Sınıflama sonuçlarında %85 doğru sınıflama başarımı elde edilmiştir. Elde edilen bu sonuçlar [7] referansındaki entropi hesaplama içerikli çalışma sonuçları ile karşılaştırılmıştır. Buna göre; entropi hesaplama tekniğinin fraktal boyut hesaplama tekniğinden daha güvenilir sonuçlar ürettiği görülmüştür.

Anahtar Kelimeler: Biyomedikal işaret işleme, Doppler ultrason, Dalgacık dönüşümü, Fraktal boyut, Yapay sinir ağları.

SUMMARY

Classification of Doppler Signals with Artificial Neural Networks using Wavelet Transform and Fractal Dimension

Recently, functional corruptions in circulation system, embolism, venoconstriction and vasolidation have been coincided very often. As a result of these problems, severe ilnesses have occured and bloodstream problems can cause to death. To prevent these illness of fatal cases, The Ultrasonic Doppler Technique, based on analysing the body area where is considered to be diseased, is used without any surgical operation to patient.

In this study, a new practical approach, based on feature extraction to classify Doppler Heart Signs, has been suggested. In this approach, wavelet transform and fractal dimension calculating is used in feauture extraction process and backpropagation artificial neural network is used in classification process. At the end of study, 85% accurate classification success has been obtained. Obtained results have been compared with the results of entropy calculation refers to reference [7]. Accordingly, it is proved that entropy calculation technique produces more reliable results than fractal dimension calculating technique.

Key words: Biomedical Signal Processing, Doppler Ultrasound, Wavelet Transform, Fractal Dimension, Artificial Neural Network.

ŞEKİLLER LİSTESİ

Sayfa No

Şekil-1.1. Veri madenciliğine yardımcı disiplinler 1
Şekil-1.2. Örüntü tanıma aşamaları 2
Şekil-1.3. Hasta teşhis sistemlerinin aşamaları 4
Şekil-2.1. İşaret analiz yöntemleri arasındaki ilişki 8
Şekil-2.2. Fourier bazlı fonksiyonların zaman-frekans düzlemini kaplaması 10
Şekil-2.3. Daubechies dalgacık bazlı fonksiyonun zaman-frekans düzlemini kaplaması 10
Şekil-2.4 Daubechies-4 ana dalgacığı ile ölçekleme dönüşüm tekniklerinin gösterilmesi 12
Şekil-2.5. Bir ızgarada ayrık dalgacıkların ölçek zaman düzleminde yerleştirilmesi .. 14
Şekil-2.6. Haar dalgacığı 15
Şekil-2.7. Meksika şapkası dalgacığı 16
Şekil-2.8. Littlewood-Paley dalgacığı 16
Şekil-2.9. Morlet dalgacığı 17
Şekil-2.10. Biortogonal dalgacıklar 17
Şekil-2.11. Coiflet dalgacığı 18
Şekil-2.12. Simetrili dalgacıklar. 18
Şekil-2.13. Meyer dalgacığı. 19
Şekil-2.14. Daubechies ana dalgacığının fraktal diye isimlendirilen kendine benzerliği.. 19
Şekil-2.15. Dalgacık ailesi örnekleri. 20
Şekil-2.16. Bir dalgacığın filtrelere ayrıştırılması. 21
Şekil-2.17. İşaretin filtrelenmiş hali. 22
Şekil-2.18. Analiz süreci ve yaklaşım. 23
Şekil-2.19. İşaret analiz-sentez sistemi 24
Şekil-3.1. Fraktal şeklin büyütülmesi 25
Şekil-3.2. Von Koch eğrisi. 28
Şekil-3.3. Ters kartanesi. 29

Şekil-3.4. Sierpinski üçgeni 30
Şekil-3.5. Sierpinski halısı. 31
Şekil-3.6. Nautilus. 32
Şekil-3.7. Beyin 32
Şekil-3.8. Kılcal damarlar 33
Şekil-3.9. Fraktal geometrinin elde edilmesine örnekler 34
Şekil-3.10. Bilgisayar programlarıyla elde edilen fraktal örnekler 34
Şekil-3.11. Mimaride fraktaller 35
Şekil-3.12. Tuz(NaCl) kütlesi ve kristal yapısı 35
Şekil-3.13. Tek boyutlu nesnede fraktal boyut 37
Şekil-3.14. İki boyutlu nesnede fraktal boyut 37
Şekil-3.15. Üç boyutlu nesnede fraktal boyut 38
Şekil-4.1. Biyolojik nöron yapısı 40
Şekil-4.2. Doğrusal etkinleştirme fonksiyonu 42
Şekil-4.3. Sigmoid etkinleştirme fonksiyonu 42
Şekil-4.4. Tanjant hiperbolik aktivasyon fonksiyonu 42
Şekil-4.5. Yapay sinir ağ yapısı 43
Şekil-4.6. Yapay sinir ağları sınıflandırılması 44
Şekil-4.7. Eğiticisiz öğrenme 45
Şekil-4.8. Eğiticili öğrenme 45
Şekil-4.9. Tek algılayıcı sinirsel ağ modeli 47
Şekil-4.10. Üç katmanlı algılayıcı sinir ağı örneği 49
Şekil-4.11. Öğrenmeli vektör 55
Şekil-4.12. İleri beslenmeli 3 katmanlı yapay sinir ağı 57
Şekil-4.13. Geri beslenmeli ağ için blok diyagram 58
Şekil-4.14. Takviyeli öğrenme yapısı 59
Şekil-5.1. İşaret sınıflama aşamaları 60
Şekil-5.2. Doppler kalp ses işaretlerinin sınıflama süreci 61
Şekil-5.3. Doppler ultrasonografi çalışma prensibi 62
Şekil-5.4. Hasta ve sağlıklı kişilerden alınan doppler işareti 63
Şekil-5.5. İşaretin işlenmesi 64
Şekil-5.6. Hamming penceresi 66

Şekil-5.7. Dalgacık dönüşümü ve fraktal boyut ile özelliklerin çıkarılması 67
Şekil-5.8. DKS işaretinin dalgacık dönüşüm ağacında bulunan işaretleri 68
Şekil-5.9. YSA eğitim başarımı-I..... 72
Şekil-5.10. YSA eğitim başarımı-II 73

TABLOLAR LİSTESİ

Sayfa No

Tablo-5.1. Bir DKS işareti için hurst exponent ile hesaplanan fraktal boyutlar 70
Tablo-5.2. Kullanılan YSA modelinin yapısı ve eğitim parametreleri 74
Tablo-5.3. DKS işaretlerinin sınıflandırılma başarımı 75

SEMBOLLER LİSTESİ

Δw_{ij}	:	Olması gereken ağırlık değişimi
a	:	Ölçekleme elementi genişleme parametresi
A	:	Alçak frekanslı işaret bileşeni
Ad	:	Geometrik biçimin hesaba katıldığı geometrik çarpan
b	:	Dönüşüm elementi
b_h	:	Hausdorff boyutu
C	:	Sesin ortamdaki hızı
D	:	Yüksek frekanslı işaret bileşeni
D	:	Fraktal boyut
d(k)	:	İstenen çıkış değeri
$e_j(u)$	:	Bütün nöronlar için hata değeri
f(x)	:	Ağ fonksiyonu
FD	:	Frekansdaki doppler kayması
Fo	:	İletilen ultrason frekansı
Fr	:	Geri dönen ultrason frekansı
g(k)	:	Yüksek geçiren filtre katsayıları
H	:	Hurts exponent
h(k)	:	Alçak geçiren filtre katsayıları
H(z)	:	FIR filtrenin transfer fonksiyonu
I_i	:	Çıkış katmanı nöronunun girişi
I_j	:	Gizli katman nöronunun girişi
Ir	:	Eğitim indeksi
It	:	Test indeksi
Kh	:	Eşkenar üçgenin yüksekliği
L	:	Kıyı şeklinin birim olarak ölçülen uzunluğu
L	:	Eğrinin uzunluğu
ℓ £$_n$	:	Temel uzunluk
L_n	:	Toplam uzunluk
Ls	:	Her parçanın uzunluğu

N	:	Toplam katsayı adedi
N	:	Filtrenin derecesi
nhs	:	Yatay parça sayısı
nis	:	Yatay olmayan parça sayısı
nv	:	Eğrideki köşe sayısı
O_i	:	Bir önceki katmanda bulunan nöron çıkışı
p	:	Çıkış katmanında bulunan nöron sayısı
s	:	SDD'nin ayrık versiyonu skalandırma parametresi
t	:	Bir önceki katmanda bulunan düğüm sayısı
T	:	Eşikleme değeri, n işaretin uzunluğu
V(t)	:	Ölçekleme fonksiyonu için genişleme denklemi
Vrbc	:	Kan akım hızı
w	:	Ağırlık vektörü
w_{ij}^{s+1}	:	Ağırlıkların alacağı yeni değer
Wn	:	Filtrenin kesim frekansı
x	:	Nörona giriş vektörü
y(x)	:	Çıkış
β	:	Öğrenme oranı
δ_j	:	Çıkış katmanında bulunan j. nöronun eğim değeri
η	:	Öğrenme hızı
θ_j	:	Eşik elemanın ağırlık değeri
$\psi(t)$	:	Dalgacık
Θ	:	Akımın yönü ile ultrason ışını arasındaki açı

KISALTMALAR LİSTESİ

A/D	:	Analog Sayısal
ADC	:	Analog Dijital Çevirici
ADD	:	Ayrık Dalgacık Dönüşümü
ÇKA	:	Çok Katmanlı Algılayıcı
ÇKAYSA	:	Çok Katmanlı Algılayıcılı Yapay Sinir Ağı
DAC	:	Dijital Analog Çevirici
DPA	:	Dalgacık Paket Analizi
DSP	:	Digital Signal Processing – Sayısal İşaret İşleme
DKS	:	Doppler Kalp Sesi
EEG	:	Elektrosefalogram
EKG	:	Elektrokardiyografi
FB	:	Fraktal Boyut
FD	:	Fourier Dönüşümü
FIR	:	Sonlu Darbe Cevabı
HFD	:	Hızlı Fourier Dönüşümü
IIR	:	Sonsuz Darbe Cevabı
İE	:	İşlem Elemanı
KZFD	:	Kısa Zamanlı Fourier Dönüşümü
LVQ	:	Öğrenmeli Vektör
MR	:	Manyetik Rezonans
SDD	:	Sürekli Dalgacık Dönüşümü
SNR	:	İşaretin Gürültü Seviyesi
SOM	:	Self Organizing Map – Kendi Kendine Organize Olabilen Haritalar
WFT	:	Windowed Fourier Transform - Pencerelenmiş Fourier Dönüşümü
YSA	:	Yapay Sinir Ağı

1. GİRİŞ

Veri madenciliği, çok büyük veri yığınlarından kritik bilgiler elde edilmesini ve bu bilgiler ışığında stratejik kararlar alınmasını sağlayan bir tekniktir. Yararlı ve anlaşılır bilgiler, çeşitli yöntem ve tekniklerin bilgisayar programlarıyla verilere uygulanmasıyla elde edilir. Bu teknikler, artan veri miktarının etkili bir şekilde kullanılmasını sağlar [1]. Veri madenciliği, veriden kullanışlı ve anlamlı bilgiyi elde ederken, Şekil 1.2'deki gibi birçok disiplinden faydalanır. Bu sayede, web üzerinde filtrelemeler, DNA sıraları içerisinde genlerin tespiti, ekonomideki eğilim ve düzensizliklerin tespiti, elektronik alışveriş yapan müşterilerin alışkanlıkları gibi karar verme mekanizmaları için önemli bulgular elde edilebilir [2].

Şekil 1.1. Veri madenciliğine yardımcı disiplinler

Veri madenciliğindeki önemli disiplinlerden biri örüntü tanımadır. Örüntü, dünyadaki tüm maddeleri nicel olarak tanımlayan verilerdir. Varlıklara ait örüntüleri insanoğlu genelde 5 duyu organıyla, yaşanmışlıklarına ve tecrübelerine dayalı olarak tanımlar. Bilgisayarın gelişimi ile insanlardaki bu tanımlama işlemleri makineler aracılığıyla gerçekleştirilmeye çalışılmıştır. İnsan fonksiyonlarının büyük bölümünü gerçekleştiren makine öğrenmesi disiplini, örüntü tanımadır. Örüntü tanıma, ortak özellikleri olan ve aralarında bir ilişki kurabilen nesneleri, tespit edilmiş özellikler veya

karakterler vasıtası ile sınıflandırılması olarak tanımlanabilir. Temel amaç, önceden bilinenlerden bilinmeyenleri ortaya çıkarmaktır [3].

Örüntü tanıma sistemini oluşması için Şekil 1.1'deki gibi temel üç temel aşama gerekir. Bunlar; işaret işleme, özellik çıkarma ve sınıflandırma aşamalarıdır.

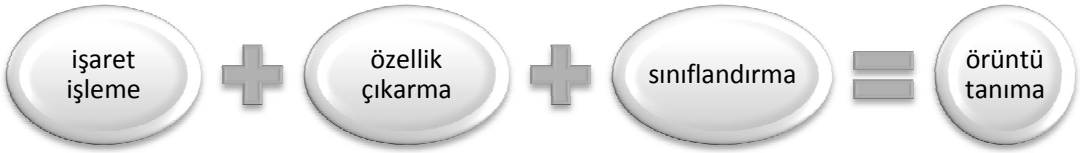

Şekil 1.2. Örüntü tanıma aşamaları

Örüntü tanıma aşamalarından ilki olan işaret işleme; işaretlerin sayı dizileri şeklinde temsil edilmesi ve bu sayı dizilerinin, sayısal hesaplama yöntemleri ile dönüştürülmesi veya işlenmesi ile ilgilidir [4]. Biyomedikal işaretler ise; röntgen, ultrason, harmonik görüntüleme, doppler, sintigrafi, manyetik rezonans, bilgisayarlı tomografi, pozitron emisyon tomografisi gibi makinelerden elde edilen işaretlerdir.

Biyotıp uygulamaları üzerinde işaret işlemenin çıkarımlarından faydalanılmaktadır. Uzaysal görüntü iyileştirme (X Ray), spektral analiz çalışmaları, 3 boyutlu görüntü işlemleri, sayısal filtreleme ve veri sıkıştırma işlemlerinde işaret işleme kullanılmaktadır [5]. İşaret işleme, tıp enstrümantasyonunun en yoğun kullanıldığı alanlardan biridir. Örneğin; elektrokardiyograf (EKG), manyetik rezonans (MR), röntgen cihazları (X-Işınları), bilgisayarlı tomografi, kan basıncı ölçüm cihazları ve buna benzer birçok cihazın temelinde algılayıcılar ve işaret işleme devrelerini içeren cihazlar bulunmaktadır [6].

1.1. Amaç

Bu tez çalışmasında, tümleşik algoritmalar kullanılarak Matlab ortamında geliştirilen yazılımlar ile durağan olmayan kalp doppler işaretlerinin doğru bir şekilde sınıflandırılması ve referans [7]'de özellik çıkarım metodu olarak kullanılan entropi hesaplama tekniği yerine, fraktal boyut hesabı kullanılarak, sonuçların başarı yönünden kıyaslanması hedeflenmiştir.

Amaç; vücudun önemli organlarından biri olan kalp için damar tıkanıklığı teşhisi yapan, doktorların teşhisine büyük oranda katkı sağlayan, bilgisayar destekli bir tanı sistemi tasarlamaktır. Böylelikle doktorlar tarafından uzun zaman harcanarak gözle yapılan

işaret analizi, daha güvenilir bir şekilde ve daha kısa sürede gerçekleştirilecek ve insan hatalarından kaynaklanan sorunlar en aza indirilecektir.

1.2. Yönelim Gerekçesi

Günümüzde, dolaşım sisteminde çeşitli fonksiyon bozuklukları, damar tıkanıklığı, damar daralması ve genişlemesi gibi rahatsızlıklara oldukça sık rastlanmaktadır. Bunlara bağlı olarak ağır hastalıklar ortaya çıkmakta ve kan akış problemleri ölüm sebebi olabilmektedir. Biyomedikal alanda, çok farklı işaretler teşhis ve tedavide hekime yardımcı unsur olarak ön plana çıkmaktadır. Bu işaretlere örnek olarak, doppler kalp ses işaretleri, nöronların hücre zarındaki iyon kanallarının voltaj işaretleri, kalp ses işaretleri, akciğer ses işaretleri gösterilebilir. Ultrasonik Doppler tekniği ile damarlarla ilgili rahatsızlığından şüphe duyulan bölgenin kan akışı incelenerek, akış düzensizliğine neden olan etmenler hastaya herhangi bir cerrahi müdahalede bulunulmaksızın teşhis edilmeye çalışılmaktadır. Ultrasonik Doppler, kandaki hareketli kırmızı kan hücresi olan alyuvarlara gönderilen ses dalgalarının gitme açısı ile dönme açısı arasındaki fark sayesinde, kanın akış hızı hakkında bilgi verir. Doppler Ultrason kullanımı kolay, maliyeti az olan bir tekniktir bundan dolayı çok tercih edilmektedir.

Kalp hastalığı teşhisi için geliştirilen örüntü tanıma sisteminin ilk aşaması olan işaret işleme safhasında işaret, dışarıdaki gürültüden temizlenmiştir. Sistemin bu aşamasında normalizasyon, beyaz gürültü ayrışımı ve filtreleme yöntemleri kullanılmıştır. Filtreleme olarak FIR filtre tercih edilmiştir. FIR filtre, çıkışın girişe bağlı olduğu tekrarsız filtredir ve sadece sıfırları olup kutupları olmadığından daima kararlı, önceden belirlenmiş genlik ve faz cevabını sağlayacak şekilde lineer fazlı olarak tasarlanabildiğinden tercih edilmiştir. İşaretlerin özellik çıkarımı yapılırken, ayrık dalgacık dönüşümü ve fraktal boyut hesabı kullanılmıştır. Özellik çıkarımı aşamasında, kalp işaretleri durağan olmadığından dolayı ayrık dalgacık dönüşümü kullanılmıştır. Özellik çıkarım aşamasında fraktal boyut kullanılmasındaki amaç; sinyalin herhangi bir geometrik şeklinin olmamasıdır. Sınıflama aşamasında ise geri yayılımlı yapay sinir ağı kullanılmıştır. Kullanılan yapay sinir ağının özelliği; en az bir hücrenin çıkışının kendisine yada diğer hücrelere giriş olarak verilmesi ve genellikle geri beslemenin bir geciktirme elemanı üzerinden yapılmasıdır.

1.3. Yöntem

Şekil 1.2' de algoritması verilen sistemin aşamaları aşağıdaki gibidir.

Şekil 1.2. Hasta teşhis sistemlerinin aşamaları

Tez çalışmasının ilk aşamasında literatür taraması yapılarak, veri madenciliği tekniklerinin işaret işleme çalışmalarına uygun olanları ile ilgili temel kavramlar ve yöntemler ayrıntılı olarak incelenmiştir. Araştırmalar sonucunda biyomedikal işaret olarak, ultrasonik doppler cihazından elde edilen kalp işaretleri ile çalışılmıştır. Ultrasonik doppler cihazından elde edilen işaretler örüntü tanıma aşamalarından geçirilerek, istenilen veriler elde edilmiştir. Bu aşamalardan ilki olan işaret işlemede, doppler cihazı ile elde edilen işaretlerin dış etkilerden arındırılması ve sinyalin daha uygun hale dönüştürülmesi için filtreleme, beyaz gürültü ayrışımı ve normalizasyon teknikleri kullanılmıştır.

İkinci aşamada, temizlenen sinyalin özelliklerinin belirlenmesi için, durağan olmayan sistemlerde kullanılan ayrık dalgacık dönüşümü kullanılarak, sinyal 13 seviyeye ayrıştırılmıştır. Ayrışan sinyallerin her bir seviyesinin hurst exponent katsayısı yardımı ile

Daubechies-10 dalgacıklarına göre *m=12* ayrışan dalgacık dönüşüm ağacından fraktal boyutları hesaplanmıştır.

Örüntü tanıma sisteminin son aşamasında, sinyaller eğitim ve test verisi olarak iki guruba ayrılmıştır. Kullanılan Matlab programı ile sistemin, verilen bilgileri öğrenme yoluyla aldığı tespit edilmiştir. Veri sınıflandırmasının yapılabilmesi için, hata geri yayılımlı ve çok katmanlı yapay sinir ağları kullanılmıştır. Bu sistemde katmanlar birbiri ile bağlantılıdır. Geri yayılımlı algoritmada, bilgi ileriye doğru akar ama hata geriye doğru çıkıştan girişe azaltılmaya çalışılır. Böylelikle ağırlıklar en uygun hale gelene kadar tekrar tekrar hesaplanır. Bu özelliklerden dolayı, giriş katmanında 13, ara katmanda 5, çıkış katmanında 2 nöronu olan sistem geliştirilmiştir. Sistem iki katlı çapraz geçerlilik ile denenmiştir. Buna göre, önce eğitim verileri test verisi ile test edilmiş, sonra test verisi eğitim olarak kullanılmış ve eğitim verisi ile test edilmiştir.

Gerçekleştirilen bu sistemde, eğitim verisinin eğitim, test verisisinin test amaçlı kullanımında sınıflama başarımı %87, test verisinin eğitim, eğitim verisinin test olarak uygulandığı sınıflamada ise %83 başarı elde edilmiştir. Sistem başarım ortalaması toplamda %85 olarak gerçekleşmiştir.

Doppler kalp işaretleri, Fırat Üniversitesi Araştırma Hastanesi Kardiyoloji Kliniği'nden elde edilmiştir. Bilgisayar ortamında Matlab Programı kullanılarak yazılımlar gerçekleştirilmiştir.

2. DALGACIK DÖNÜŞÜMÜ

2.1. İşaret İşleme

İşaret, gerçek dünyadan elde edilen büyüklüklerin zamanın bir fonksiyonu olarak ifade edilmesidir [8]. İşaret işleme ise, işaretin birtakım matematiksel dönüşümler uygulanarak işlenebilir hale getirilmesidir. İşaret işleme, bilgisayar bilimi ve mühendislik alanındaki gelişim etkinliklerinin ve çağdaş bilimin bir parçası haline gelmiştir ve telekomünikasyonda, teşhis-tanı sistemlerinde, kontrol uygulamalarında, zaman serilerinin tahmini gibi bilgisayar destekli mühendislikte çok önemli bir yere sahiptir.

İşaretler, kendi aralarında durağan ve durağan olmayan olmak üzere gruplandırılır. Durağan işaretlerin istatistiksel bilgileri zamanın tüm noktalarında aynıdır, fakat genlik zamanla değişir. Durağan olmayan işaretlerde ise bu bilgiler zamanla değişim gösterir.

İşaret işlemede bilgi genelde işaretin içerdiği frekans bilgisinde olabilir. Durağan işaretlerin zamanla istatistiksel özellikleri değişmediğinden, analizi için hızlı sayısal metotlar kullanmak mümkündür. Fourier dönüşümü olarak adlandırılan bu durum, zamanın önemli olmadığı işlemlerde kullanılır ve işaretin tamamı hakkında bilgi verir.

Fourier dönüşümü, durağan olmayan işaretlerde tercih edilmez. Çünkü, işaretin geçici ve şekilsel değişimlerini saptayamaz. Eğer işaretin tamamına değil de belirli bir kısmındaki bilgilere ulaşmak gerekirse; yani durağan olmayan işaretlerin işlenmesinde, Kısa Zamanlı Fourier Dönüşümü kullanılmalıdır. Kısa Zamanlı Fourier Dönüşümü zamanı belli aralıklara böler ve zamanın önemli olduğu çalışmalarda bu alanlardaki bilgiler kullanılır.

Zamanın herhangi bir anı isteniliyorsa bu işaret işleme teknikleri uygun olmaz. Örüntü tanımada işaretin tanınmasında, durağan olmayan işaretlerin özelliklerinin doğru bir şekilde ve yüksek başarımla tanınması önemlidir [9]. İşaretin tanımlayıcı özellik seçiminde işaretin hem geçici ve hem de frekans değişim bilgilerini içeren zaman–frekans gösterimleri etkilidir [10].

2.2. Dalgacık Dönüşümü

Dalgacık dönüşümü gürültü temizleme gibi işaret işleme uygulamalarında başarılı sonuçlar veren bir işaret dönüşüm tekniğidir. Dalgacık dönüşümü istenilen herhangi bir zaman diliminde olan, anlık değişen, durağan olmayan işaretleri işlemek için kullanılır. Dalgacık dönüşümleri günümüzde bir çok mühendislik uygulamasında durağan ve durağan olmayan süreçlerin zaman–frekans gösterimlerinde en başarılı sonuçları veren kullanışlı ve güçlü bir araçtır [11].

Dalgacık dönüşümü işaretin ölçeklenebilir bir zaman frekans gösterimi ile analizini sağlar ve geleneksel işaret işleme teknikleri tarafından görülmeyen detayları meydana çıkarır. Dalgacık dönüşümü işarete ölçekleme ve öteleme özelliği kazandırır. Dalgacık dönüşümünde işaretler analiz edilirken, analiz penceresinin uzunluğu ve konumu kendiliğinden değişmektedir. Kısa Zamanlı Fourier Dönüşümü'nde (KZFD) analiz penceresi kaydırılabildiği halde, pencere uzunluğu analiz boyunca sabit kalmaktadır.

Dalgacık dönüşümü analizi, düşük frekans bilgisinin önem kazandığı araştırmalar için büyük zaman aralıklarının, yüksek frekans bilgisinin önemli görüldüğü araştırmalar için de daha küçük zaman aralıklarının kullanılmasına izin veren farklı ölçek bölgelerine sahip bir pencereleme tekniğidir. Dalgacık dönüşümleri ile durağan olmayan işaret alt bileşenlerine ayrılarak durağan hale getirilmektedir [12].

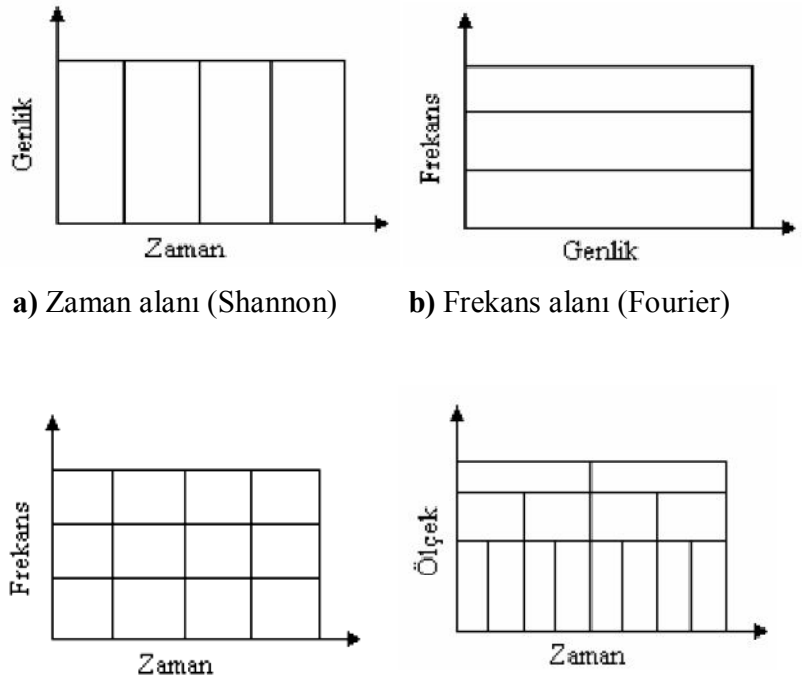

a) Zaman alanı (Shannon) **b)** Frekans alanı (Fourier)

c) KZFD **d)** Dalgacık dönüşümü

Şekil 2.1. İşaret analiz yöntemleri arasındaki ilişki [12]

Zaman tanım alanında bir işaretin zaman-genlik grafiği Şekil 2.1a'da gösterilmiştir. Bu tanım alanında gösterim, bir işaretin analizi için çok fazla bir değer ifade etmez. Dolayısıyla, işaretlerin frekans genlik spektrumlarının araştırılmasına ihtiyaç duyulur. Böyle bir durumda, Fourier dönüşümünü kullanmak yeterli olacaktır. Ancak bu da işaretin tamamı hakkında bilgi verecektir (Şekil 2.1b) [13].

İşaretin ayrı bölgelerde, farklı frekans bantlarında incelenmesi için, işaretin belirli bir ölçekteki bir pencere fonksiyonu ile çarpılmasını temelli bir yöntem olan Kısa Zaman Fourier Dönüşümü ortaya atılmıştır. Bu grafik, Şekil 2.1c'de gösterilmiştir. Ancak pencerelerin eşit aralıkta olması, işaret analizinde daha küçük ve daha büyük frekansların incelenebilmesi için bir sıkıntı teşkil eder. Bu sorunu gidermek için oluşturulan dalgacık dönüşümü analizi, düşük frekans bilgisinin önem kazandığı araştırmalar için büyük zaman aralıklarının, yüksek frekans bilgisinin önemli görüldüğü araştırmalar için de daha küçük zaman aralıklarının kullanımına yön vermektedir (Şekil 2.1d) [13].

Fourier ve Dalgacık Dönüşümleri Arasındaki Benzerlikler:

Hızlı Fourier dönüşümü (HFD) ve ayrık dalgacık dönüşümünün (ADD) her ikisi de doğrusal işlemlerdir. Bu işlemler, genellikle doldurarak ve 2^n uzunluğundaki farklı bir veri vektörüne dönüştürerek bir veri yapısı üretir. Bu veri yapısı çeşitli uzunluklara sahip $log2^n$ sayıda parça içerir [14].

Dönüşümlerde kullanılan matrislerin matematiksel özellikleri de benzerdir. Hızlı Fourier Dönüşümü ve Ayrık Fourier Dönüşümünün her ikisi için ters dönüşüm matrisi orijinal matrisin transpozudur. Sonuç olarak, her iki dönüşüm, fonksiyon uzayında farklı tanım bölgesine dönüştüren hareket gibi görülebilir. Hızlı Fourier dönüşümü için bu yeni tanım bölgesi sinüs ve kosinüsten oluşan baz fonksiyonlarını içerir. Dalgacık dönüşümü için bu yeni tanım bölgesi dalgacıklar, ana dalgacıklar veya analiz eden dalgacıklar diye isimlendirilen daha karmaşık baz fonksiyonlarını içerir [15].

İki dönüşümün başka bir benzerliği de vardır. Baz fonksiyonları frekans ile sınırlandırılırlar. Bu, güç tayfı (bir frekans aralığında ne kadar güç bulunduğu) ve güç dağılımlarını hesaplamada yararlı olan matematiksel araçları oluşturur [14].

Fourier ve Dalgacık Dönüşümleri Arasındaki Farklılıklar:

Bu iki tür dönüşüm arasındaki en ilginç farklılık her dalgacık fonksiyonunun uzayda sınırlandırılmasıdır. Fourier sinüs ve kosinüs fonksiyonları böyle değildir. Dalgacıkların frekans sınırlaması düşünüldüğünde, bu sınırlandırma özelliği, dalgacık tanım bölgesine dönüştürüldüğü zaman seyrek dalgacıklar kullanan birçok fonksiyon ve operatör oluşturur. Tersten bakıldığında bu seyreklik, veri sıkıştırma, resimlerdeki özellikleri bulma ve zaman serilerindeki sorunları ortadan kaldırma gibi yararlı bir sürü uygulamayla sonuçlanır [15].

Fourier dönüşümü ve dalgacık dönüşümü arasındaki zaman–frekans çözünürlük farklarını görmenin bir yolu, zaman – frekans düzleminde baz fonksiyonunun kapladığı alana bakmaktır. Şekil 2.2, penceresinin basit olarak kare dalga olduğu bir pencerelenmiş Fourier dönüşümünü göstermektedir. Kare dalga penceresi, pencereyi belirli bir genişliğe ayarlayacak şekilde sinüs veya kosinüs fonksiyonunu keser. Pencerelenmiş Fourier dönüşümünde (WFT)

bütün frekanslar için tek bir pencere kullanılması nedeniyle, çözünürlük analizi zaman–frekans düzlemindeki bütün bölgelerde aynıdır [15].

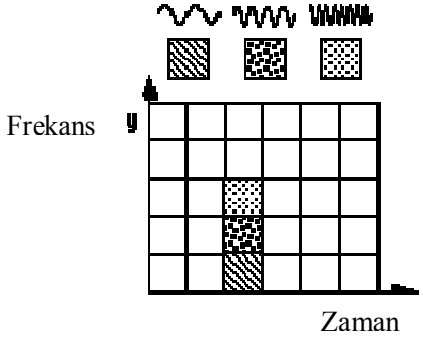

Şekil 2.2. Fourier bazlı fonksiyonların
zaman-frekans düzlemini kaplaması [15]

Dalgacık dönüşümlerinin bir avantajı pencerelerin değişebilir olmasıdır. İşaret süreksizliklerini ayırmak için bazı çok kısa baz fonksiyonlarına sahip olmak istenir. Bunu gerçekleştirmenin bir yolu kısa yüksek–frekans baz fonksiyonları ve uzun düşük–frekans baz fonksiyonlarına sahip olmaktır. Şekil 2.3, Daubechies dalgacığı diye isimlendirilen bir dalgacık fonksiyonunun zaman–frekans düzleminde kapladığı alanı göstermektedir [15].

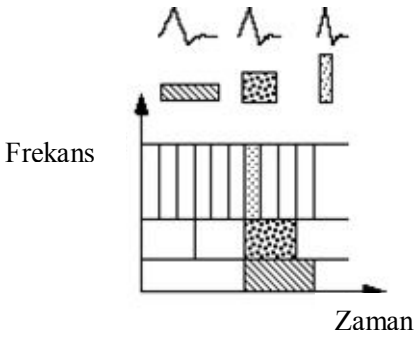

Şekil 2.3. Daubechies dalgacık bazlı fonksiyonun
zaman-frekans düzlemini kaplaması [15]

Dalgacık dönüşümlerinin, sadece sinüs ve kosinüs fonksiyonlarını kullanan Fourier dönüşümü gibi tek bir baz fonksiyonları kümesine sahip olmadığıdır. Onun yerine, dalgacık dönüşümleri sonsuz sayıda mümkün baz fonksiyonları kümesine sahiptir. Bundan dolayı dalgacık analizi, Fourier analizi gibi diğer zaman–frekans yöntemleri tarafından saklı bırakılan bilgiye doğrudan erişim sağlar [14].

Günümüzde en fazla kullanılan dalgacık çeşitleri Mexican Hut, Heer, Coifiet, Meyer, Symlet ve en önemlisi Daubechies'dir [14].

2.3. Dalgacık Dönüşümü Türleri

2.3.1. Sürekli Dalgacık Dönüşümü (SDD)

Sürekli Dalgacık Dönüşümünde ölçeklemeler yapılır. Yapılan ölçeklemelerde tüm ölçeklerde dalgacık katsayıları hesaplanır. Bu, sistemin sonucu daha uzun sürede bulmasına ve gereksiz verilerle sistemin hantallaşmasına sebep olur. Fourier Analizi gibi sinüzoidal bileşenleri çözemez. Avantajı ise frekansların özellikleri farklı ise kullanımı iyi sonuçlar verir ve geçici olayların yerini kolaylıkla saptayabilir [7].

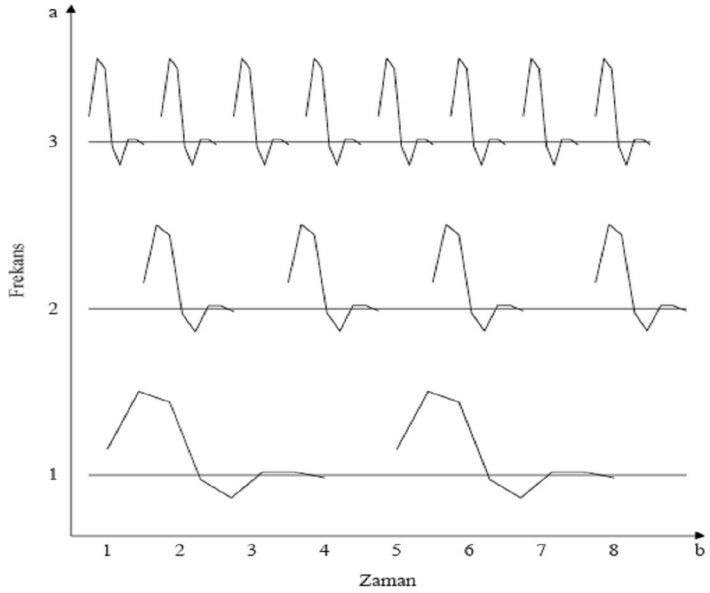

Şekil 2.4. Daubechies-4 ana dalgacığı ile ölçekleme ve dönüşüm tekniklerinin gösterilmesi [7]

Şekil 2.4'de bir ana dalgacık ile ölçekleme ve dönüşüm işleminin nasıl yapıldığı gösterilmiştir. Dönüşüm sonucu, zamanın bir fonksiyonu olarak işaret ve dalgacık arasında nasıl karşılıklı bir ilişki (korelasyon) olduğunu gösterir. İşaret ve dalgacık iyi eşleşmişse işaret ve dalgacık arasındaki korelasyon yüksek olur. Uygulamalara bağlı olarak dalgacık türü seçilir. Sürekli Dalgacık Dönüşümündeki ölçekleme kavramı Fourier Dönüşümündeki frekansın tersine benzerdir. Dalgacık yüksek oranda sıkışık olduğunda işaretin yüksek frekans detaylarını elde eder. Dalgacık tamamen genişse dalgacığın uzunluğu, işaretin uzunluğu ile daha uygun benzerlik sağlar ve böylece işaretin düşük frekans eğilimleri ortaya çıkar [7].

Sürekli Dalgacık Dönüşümünde ana dalgacık aşağıdaki şekilde hesaplanır:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}}\Psi\left(\frac{t-b}{a}\right) \qquad \textbf{(2.1)}$$

$\psi(t)$ dalgacık, a ölçekleme elementi genişleme parametresidir. b dönüşüm elementi ise ötelemeyi sağlar [7].

Sürekli dalgacık dönüşümü ise:

$$\psi f(a,b) = \int f(t)\psi_{b,a}dt \quad \textbf{(2.2)}$$

Burada *ψ(t)* dalgacık çözümü olarak bilinen bir pencere fonksiyonu, *a* ölçekleme faktörü olarak bilinen genişleme parametresi ve *b* dönüşüm parametresidir. *1\a* frekansın ölçümüdür. *b* parametresi, *x* ekseni boyunca dalgacık parametresinin yerini göstermektedir. Dalgacıklar ölçekleme faktörü kullanılarak sıkıştırılır ya da genişletilirler. Düşük ölçeklerde yüksek frekans davranışları, yüksek ölçeklerde düşük frekans davranışları daha iyi çözümlenir. Eğer işaret, farklı frekans özelliklerine ait karakteristikler içeriyorsa, bu mükemmel bir fayda sağlar [16].

2.3.2. Ayrık Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümünde yapılan işlemler sonucunda gerekli gereksiz birçok veri elde edilir. Bu veriler zaman fazlalığı, işlem hantallığı ve verilerin kaydedildiği alanın fazlalığı açısından sistemi olumsuz olarak etkiler. Bunlar göz önüne alınarak Ayrık Dalgacık Dönüşümü kullanılır.

Ayrık Dalgacık Dönüşümünde dönüşüm seviye seviye yapılmaktadır, seviye ilerledikçe dalgacığın ölçeği iki kat artmaktadır. Zaman ekseni de aynı şekilde örneklenmektedir. Seviye her artırıldığında dalgacık fonksiyonu iki kat genişlemekte ve hesaplanacak katsayı miktarı yarıya düşmektedir. Şekil 2.5'de Ayrık Dalgacık Dönüşümünün ölçek zaman eksenlerinin örneklenmesi grafik halinde gösterilmektedir [17].

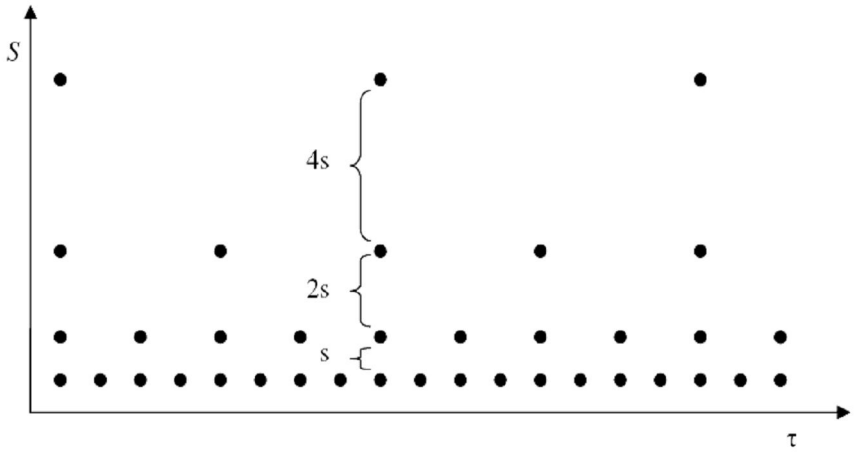

Şekil 2.5. Bir ızgarada ayrık dalgacıkların ölçek zaman düzleminde yerleştirilmesi [17]

Ayrık dalgacık dönüşümünde işaret ayrık adımlarla ölçeklenir, ötelenir ve işaret süreklidir. Sürekli Dalgacık Dönüşümünün ayrık versiyonu skalandırma parametresinin $s=a_0^j$ şeklinde ayrıştırılması ve zamanda ötelemenin bu skalandırma parametresiyle orantılı olarak gerçekleşmesi ($u=k$) ile elde edilir. Bu skala ve öteleme parametrelerine göre Sürekli Dalgacık Dönüşümü için verilen denklem yeniden yazılırsa aşağıdaki denklemden ayrık baz fonksiyonlarının ifadesi elde edilir [17].

$$\Psi_{jk} = \frac{1}{a_0^j} \Psi\left(\frac{\tau - k b_0 a_0^j}{a_0^j}\right) \tag{2.3}$$

Bu yolla, alçak frekansları analiz eden geniş pencereler (j'nin büyük değerlerine karşılık Ana Dalgacık Fonksiyonundan elde edilen baz fonksiyonları) büyük adımlarla u ötelenmiş olur. Aynı şekilde yüksek frekansları analiz eden dar pencereler (j'nin küçük değerlerine karşılık Ana Dalgacık Fonksiyonundan elde edilen baz fonksiyonları) işaretdeki hızlı değişimleri yakalamak amacıyla, küçük adımlarla ötelenmiş olur [17].

2.3.3. Dalgacık Paket Analizi

Dalgacık Paket Analizi (DPA) ADD' ye benzer olup, işaret üzerinde mümkün olan bir çok ayrışımları üretir ve ADD bunlardan sadece biridir. Filtre bankası her bir zaman için düşük frekans bileşenlerini tam olarak ayrıştırmak yerine, yüksek frekans bileşenlerini daha iyi ayrıştırmayı mümkün kılar. Böylece tüm zaman-frekans düzlemi mümkün olan tüm alt bölümlere, farklı zaman–frekans pencereleri ile bölünür [18].

2.4. Dalgacık Çeşitleri

2.4.1. Haar Dalgacığı

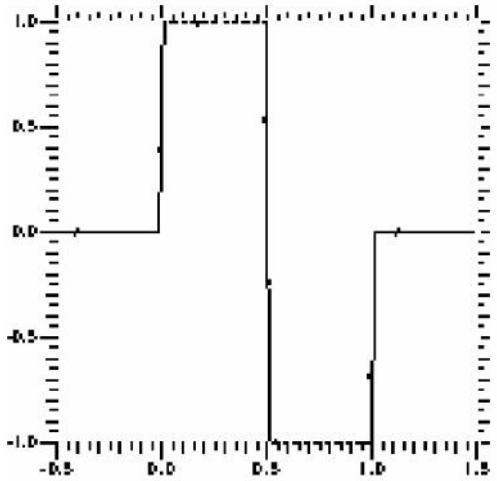

Şekil 2.6. Haar dalgacığı [18]

Haar dalgacığı sınırlı bir alandaki basamak fonksiyonudur ve simetrik ana fonksiyon kare dalga olarak da bilinir. Hem sürekli hem de ayrık dalgacık dönüşümü yapılabilir. Bu baz tek bit işaret işleme uygulamalarında yaygındır ve dalgacık dönüşümünün özelliklerini meydana çıkarmak açısından yararlıdır [19].

2.4.2. Meksika Şapkası

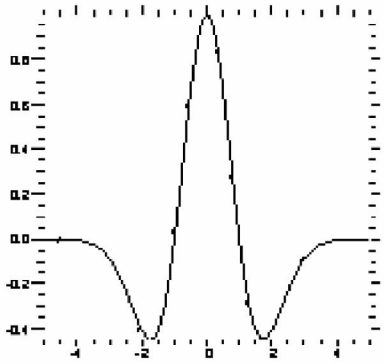

Şekil 2.7. Meksika şapkası dalgacığı [15]

Şekil 2.7'deki fonksiyona Meksika Şapkası denir. Bu eğri simetrik ana fonksiyon Gauss dağılım fonksiyonunun ikinci türevidir. Ölçek fonksiyonu olmadığı için ayrık dalgacık dönüşümü yapılamaz. Görüntü işleme fonksiyonlarında kullanılır [15].

2.4.3. Littlewood–Paley Dalgacığı

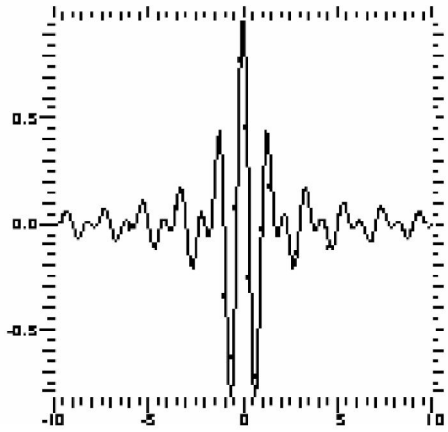

Şekil 2.8. Littlewood–Paley dalgacığı [15]

Bir ana fonksiyondan üretilmiş, ayrık dönüşümde kullanımı az olan simetrik bir dalgacıktır [15].

2.4.4. Morlet Dalgacığı

Ayrık dalgacık dönüşümünde kullanılmayan simetrik ve ölçek fonksiyonu olmayan bir dalgacıktır. İki bölümden oluşur. Bunlar gerçel ve sanal bölümdür [15].

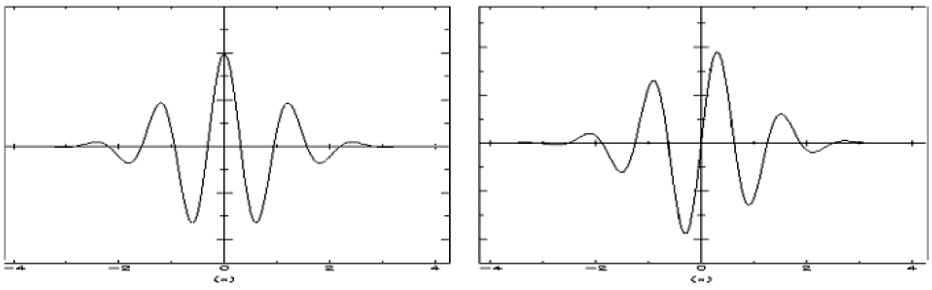

Şekil 2.9. Morlet dalgacığı [15]

2.4.5. Biortogonal Dalgacıklar

Sürekli ve Ayrık Dalgacık Dönüşümünde kullanılan simetrik dalgacıklardır [15].

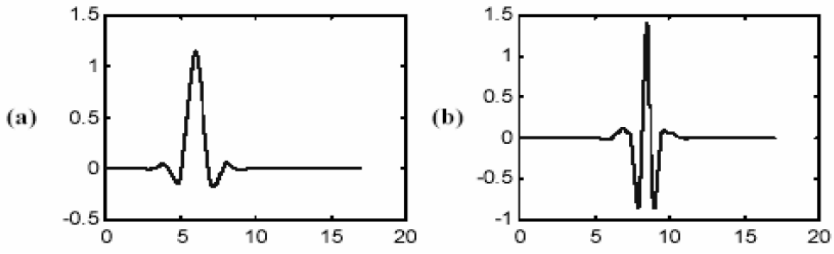

Şekil 2.10. Biortogonal dalgacıklar [15]

2.4.6. Coiflet Dalgacığı

Her iki dalgacık dönüşümünde de kullanılabilen tam simetrik olmayan dalgacıklardır [15].

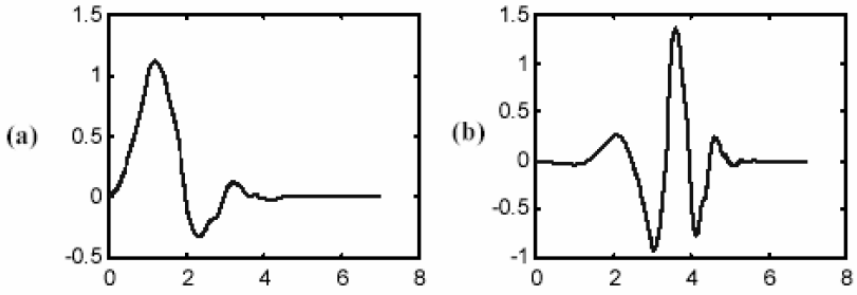

Şekil 2.11. Coiflet dalgacığı [15]

2.4.7. Simetrili Dalgacıklar

Simetriye yakın her iki dalgacık dönüşümünde de kullanılan dalgacıklardır [15].

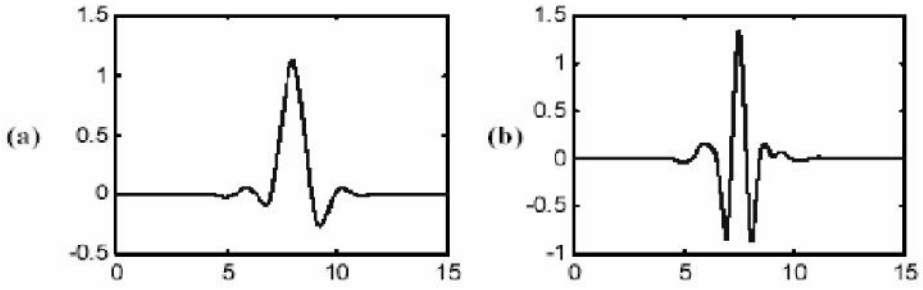

Şekil 2.12. Simetrili dalgacıklar [15]

2.4.8. Meyer Dalgacığı

Simetriktir ve her iki dalgacık dönüşümünde kullanılırlar [15].

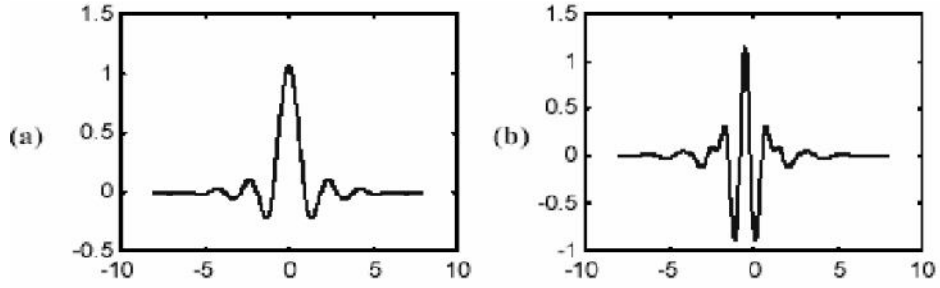

Şekil 2.13. Meyer dalgacığı [15]

2.4.9. Daubechies Dalgacığı

Dalgacık fonsiyonları içerisinde en çok kullanılan dalgacık fonksiyonudur. Simetrik değillerdir, ama Ayrık Dalgacık Dönüşümü ve Sürekli Dalgacık Dönüşümünde kullanılabilirler.

Dalgacık bazlarından birkaçı fraktal yapıya sahiptir. Daubechies dalgacık ailesi buna bir örnektir [15].

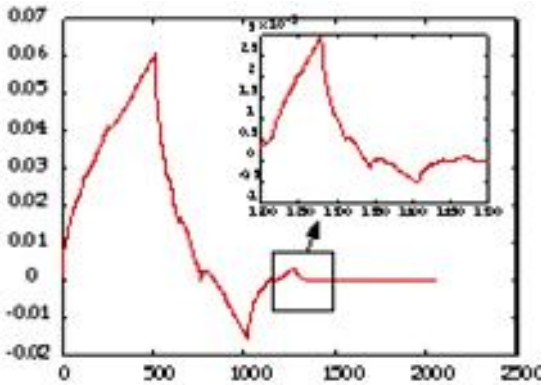

Şekil 2.14. Daubechies ana dalgacığının
fraktal diye isimlendirilen kendine benzerliği [20]

Her dalgacık ailesi içerisinde (örneğin Daubechies ailesi), katsayıların sayısı ve tekrarlama seviyesi tarafından ayırtedilen dalgacık alt sınıfları vardır. Dalgacıklar çoğu zaman sıfırlandığı anların sayısına göre bir aile içinde sınıflandırılırlar. Bu sağlanması gereken katsayılar için ekstra bir matematiksel ilişkiler kümesidir ve doğrudan katsayıların sayısı ile alakalıdır. Örneğin, Coiflet dalgacık ailesi içerisinde iki sıfır anı olan Coifletler ve üç sıfır anı olan Coifletler vardır. Şekil 2.15'te birkaç farklı dalgacık ailesi örneklerle gösterilmiştir [15].

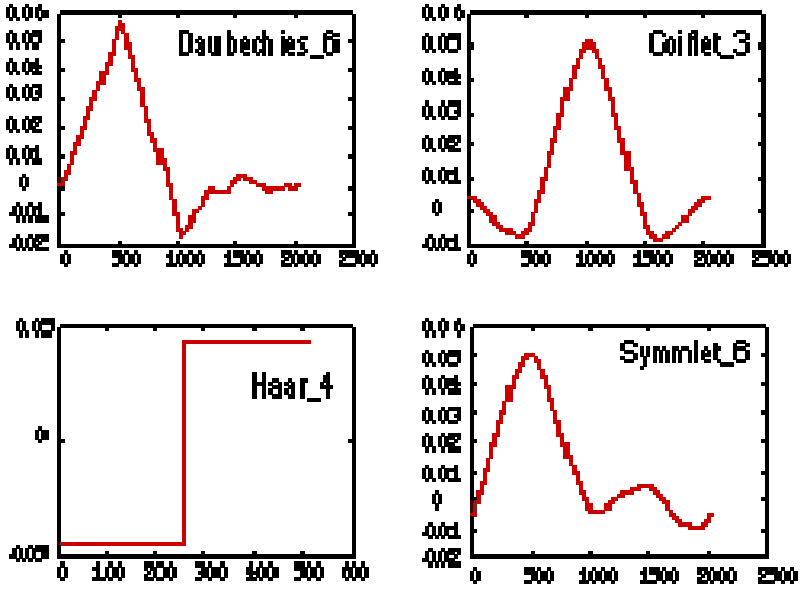

Şekil 2.15. Dalgacık ailesi örnekleri [20]

Daubechies dalgacığının açık ifadeleri yoktur, ama dalga uzunluğunu *2N-1* ile bulmak mümkündür. Burada *N* dereceyi ifade etmektedir. Temel ayrık dalgacık dönüşümlerinden biridir. *A* alçak frekanslı işaret bileşeni ve *D* yüksek frekanslı işaret bileşeni olmak üzere, *f* işareti aşağıdaki şekilde hesaplanır [13].

$$F=A_m+D_m+D_{m-1}+\ldots..+D_2+D_1 \quad \textbf{(2.4)}$$

2.5. Filtreleme

Birçok işaret için alçak frekans bileşeni işaretin en önemli parçasını oluşturur. Diğer yandan yüksek frekans bileşenleri işaretin ayrıntısıdır. Örneğin insan sesi için yüksek frekans bileşeni ortadan kaldırılırsa, sesin tonu değişikliğe uğrar [20].

Tek bir filtre belirli bir frekans cevabına sahiptir ve işaret filtreden geçtikten sonra işaretin içindeki bilgi kaybolur. Bu yüzden tek bir filtre, filtre edilmiş işaretten tekrar asıl işareti yeniden elde etmek için kullanılmaz [7]. Aynı işareti tekrar elde etmek için hem alçak geçiren hem de yüksek geçiren filtre kullanılır. Bu filtrelerden geçen işaret yaklaşım ve detay diye iki sonuç ortaya çıkarır.

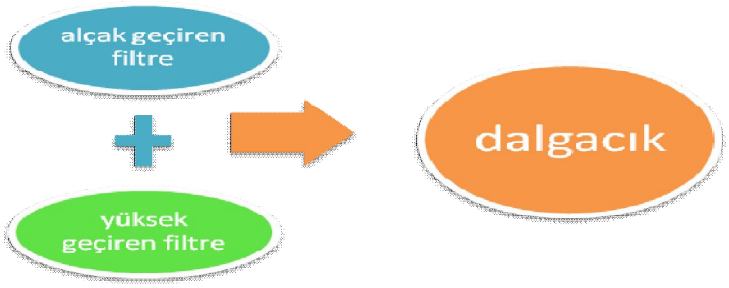

Şekil 2.16. Bir dalgacığın filtrelerle ayrıştırılması

Şekil 2.17'de *S* işaretdir ve *A* alçak geçiren frekanslı bileşenlerini, *Y* ise yüksek geçiren frekanslı bileşenlerini göstermektedir.

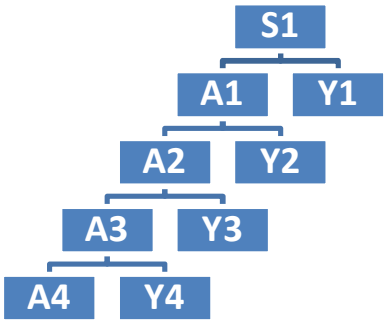

Şekil 2.17. İşaretin filtrelenmiş hali

Dalgacık dönüşümünde kullanılan yüksek geçiren filtreler dalgacık fonksiyonu, alçak geçiren filtreler ölçekleme fonksiyonu ile ilgilidir. Orijinal filtre katsayıları kullanılarak *V(t)* ölçekleme fonksiyonu için genişleme denklemi ve *ψ(t)* dalgacık fonksiyonu dalgacık denklemi aşağıdaki denklemlerle tanımlanır [20].

$$V(t) = 2\sum_{k=0}^{N} h(k)V(2t-k) \quad \textbf{(2.5)}$$

$$\psi(t) = 2\sum_{k=0}^{N} g(k)V(2t-k) \quad \textbf{(2.6)}$$

Burada *h(k)* alçak geçiren filtre katsayıları ve *g(k)* yüksek geçiren filtre katsayılarıdır. *g(k)* ve *h(k)* arasındaki ilişki aşağıdaki şekilde tanımlanır. Buradaki *N* toplam katsayı adedini göstermektedir [13].

$$g(k) = (-1)^{k}h(N-k) \quad \textbf{(2.7)}$$

Alçak ve yüksek geçiren filtrelerden istenilen sonuçlar elde edilmezse, işaret tekrardan filtrelenir. Filtreleme bilgiyi elde edene kadar devam eder. Alçak geçiren filtre *H*, yüksek geçiren filtre ise *G* olarak gösterilirse, analiz süreci aşağıdaki şekilde olur [21].

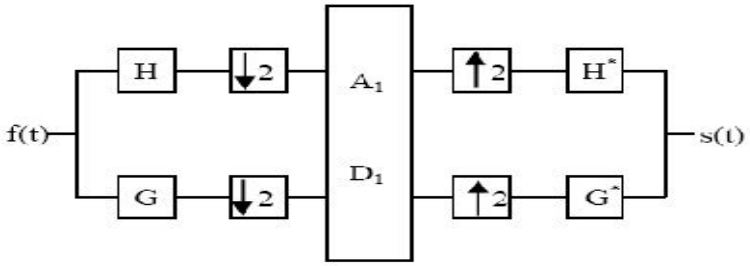

Şekil 2.18. Analiz süreci ve yaklaşım [20].

Şekil 2.18'den de görüldüğü gibi ayrık dalgacık dönüşümü, işareti farklı frekans bantlarında ve farklı çözünürlükte, işlenmemiş yaklaşım ve ayrıntı değerlerinin bilgilerini ayrıştırarak, analiz eder. Yaklaşım değerleri, işaret alçak frekans *H* süzgecinden geçtikten sonra elde edilir ki bu süzgeç yüksek frekans bileşenlerini bastırır. Bu aşamada çözünürlük yarıya iner, ancak ölçek aynı kalır. Yani işaretdeki örnek sayısı yarıya inmiş olur. Böylece gereksiz örnekler aldırılmış olur. Bu işlem çözünürlüğe etki etmez, ancak ölçeği etkiler. Benzer biçimde ayrıntı değerleri da yüksek geçiren süzgeç *G*'den geçerek elde edilir. Bu işlemler 1. seviye ayrıştırma işlemidir. Her seviyede yaklaşım değerlerine aynı işlemler uygulanır. Elde edilen katsayılar, işareti işlemede kullanılır [21].

2.6. Biyomedikal Alanında Dalgacık Dönüşümü Uygulamaları

Son zamanlarda tıbbi teşhis ve araştırmalarda kullanılan EEG işaretleri sadece zaman alanında değil de frekans alanında da incelenmeye başlanmış ve bilgisayarların gelişmesiyle çeşitli algoritmalar geliştirilmiştir. Bu algoritmalar yardımıyla teşhis ve analizler, değişik yorumlamaları ortaya çıkarmıştır. EEG işaretlerine, dalgacık dönüşümü uygulanarak tıbbi teşhis ve araştırmalara yardımcı olacağı düşünülmüş ve dalgacık dönüşümü, kısa-zaman Fourier dönüşümü ile EEG işaretleri üzerine uygulanarak karşılaştırma yapılmıştır [22].

Ses işaretlerinin iletilmesinde ve depolanmasında verimliliği artırmak için en önemli yöntemlerden biri ses kodlamadır. İletimde verimlilik bant genişliğinin veya bit oranının azaltılmasıyla sağlanır. Depolamada ise ses işaretinin en düşük bit oranında saklanması hedeflenir. Ses işareti sıkıştırmanın kullanıldığı başlıca alanlar; telefon haberleşmesi, telsiz

haberleşmesi, özel gizli ses güvenliği, dijital ses yayıncılığı, CD, frekans modülasyon kanalları üzerinden ses ve yüksek çözünürlüklü televizyonlardır. Ses işaretinin kodlanmasında kullanılan yöntemlerden biri olan alt band kodlama tekniği genel anlamda Şekil 2.19'de görülmektedir [22].

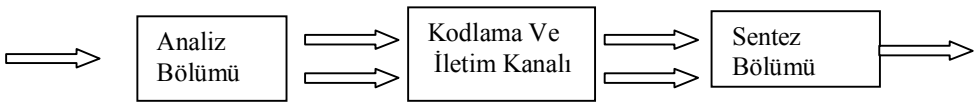

Şekil 2.19. İşaret analiz-sentez sistemi

Burada analiz ve sentez bölümlerinde dalgacık dönüşümü kullanılarak alt bandlara ayrıştırma işlemi gerçekleşmektedir.

Dalgacık dönüşümününde uygulama kolaylığı olduğu için, konuşma işaretlerini sıkıştırmaya ihtiyaç duyulan telekonferans sistemleri ve yarı iletken tabanlı telesekreter sistemlerinde bu dönüşüm kolayca kullanılabilir [22].

3. FRAKTAL ANALİZ

3.1. Fraktallerin Tanımı

Fraktaller parçalanmış ya da kırılmış, kendi kendini tekrar ederek sonsuza kadar küçülen, kendine benzer bir cisimde cismi oluşturan parçalardır. Fraktal bir şeklin her parçası büyüttüldüğünde, şekil yine cismin kendisine benzer. Düzensiz ayrıntıları ya da desenleri vardır ve bunlar giderek küçülen ölçeklerde yinelenirler [23].

Fraktallerin ayrıntıları, biçimleri giderek küçülen ölçeklerle yinelenir. Düzensiz ayrıntılar, desenler giderek küçülen ölçeklerle yinelenir ve tümüyle sonsuza kadar sürebilir. Fraktallerin her parçası büyütüldüğünde yine kendine benzeyen şekiller ortaya çıkar [24]. Fraktal analiz ise, kendi kendini tekrar eden ama sonsuza kadar küçülen şekilleri, kendine benzer bir cisimde cismi oluşturan parçaları ya da cismin bütününü inceler [25].

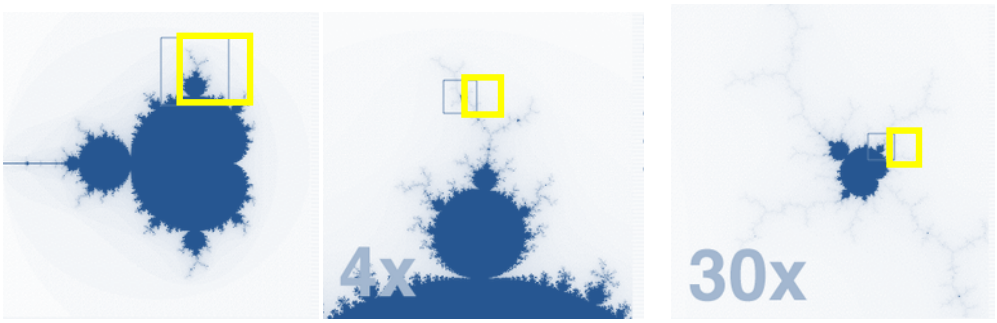

Şekil 3.1. Fraktal şeklin büyütülmesi [26]

Şekil 3.1'de görüldüğü gibi her parçanın bir kısmı büyütüldüğünde yine kendine benzer.

3.2. Fraktal Geometri

Fraktal geometri İngiltere'nin kıyıları gibi çok kıvrımlı olan uzunlukları ölçmedeki zorluklardan dolayı ortaya çıkmıştır. Bu kıyıları ölçmek için, bir harita kullanarak ölçeğe bağlı işlemler yapmak ya da kıyıyı adım adım ölçmek gibi birçok yöntem kullanılabilir. Kıyıyı adım adım ölçmek en kesin sonuçtur ve ölçmede kullanılan uzunluk birimi küçük alınırsa ölçüm sonucu sonsuza yönelebilir. *Benoit Mandelbrot* gibi bir matematikçi bu verileri dikkate alarak, 'fraktal geometri' denilen yeni bir matematik yaklaşımının temelini atmıştır. Doğadaki bu şekillere latince 'kırıklı' anlamına gelen 'fractus' sözünden 'fractal' ismi verilmiştir [27].

Fraktal olarak isimlendirilen şekiller, matematik alanına Alman matematikçi *Cantor* (1845-1918) ile girmiştir. Cantor küme teorisini oluşturan kişidir. Fraktaller *Cantor, Sierpinski, Von Koch, Peano* gibi matematikçilerin dikkatini çekmiştir. Cantor kümesi görünüş açısından diğerlerinden daha az gösterişli olmasına ve diğerlerine göre yoruma daha uzak olmasına rağmen özelikle Kaotik Dinamik Sistemlerde oldukça önemlidir [28].

Fraktal geometri, klasik geometrinin üzerine inşa edilmiş bir yapıdır. Öklid geometrisinin bir uzantısıdır ve galaksideki fiziksel yapıları tanımlamada kullanılan yeni bir oluşumdur. *Öklid* geometrisine göre bir doğru parçası sadece uzunluk boyutuna sahiptir. Örneğin bir kağıdın üzerine bir çizgi çekince tek boyutlu şekil görünür. Kağıdın üzerindeki çizgilerin sayısını artırarak yüzeyi eğri büğrü birçok çizgi ile doldurduğumuzda ise yine tek boyutlu şekil elde edilir. Karalama işi tüm kağıt doluncaya kadar sürdürülürse sonuç olarak iki boyutlu bir düzlem elde edilir [29].

Matematik biliminde kullanılan klasik geometri sadece insan yapımı nesneleri tanımlamada kullanılır. Fraktal geometri ise doğada bulunan nesneleri tanımlamak için kullanılan bir yöntemdir ve hem doğanın benzetimlerinde kullanılır, hem de sanatsal değer taşırlar. Fraktal geometri meteoroloji, akışkan dinamiği, ekonomi, biyoloji vb. dinamik sistemlerin açıklanmasında önemli rol oynar [30].

Fraktal geometrinin ölçek farklılığı ile kendine benzer parçalar oluşturma tekniği son yıllarda rastgele özelliklerden oluşan fiziksel sistemlerin incelenmesinde giderek daha yaygın olarak kullanılmaya başlanmıştır. Örneğin, gökada kümelerinin evrendeki dağılımının saptanmasında ve akışkan burgaçlanmalarına ilişkin problemlerin çözülmesinde fraktal benzetimlerden yararlanılmaktadır. Doğanın geometrisi olan fraktal geometri, eski uygarlıkların bir çoğunda (Avrupa, Afrika, Maya, Hindistan, İslam Mimarisi

vb.) ve mimari eserlerde plan formu, cephe ve üç boyutlu süslemelerde bilinçli birşekilde olmasa da kullanılmıştır [31].

3.2.1. Fraktal Geometrinin Özellikleri ve Klasik Geometri

Fraktal geometri, Öklid geometrisi gibi 2000 yıllık bir geçmişe sahip değildir. Bilgisayar teknolojisinin gelişimi ile çok fazla detaya sahip olan sistemler oluşturulduğundan bu alandaki çalışmalar hızlanmıştır. Basit denklemler klasik geometri ile çözümlenirken, yapısında pek çok küçük kopyasını barındıran, detaylı yapıya sahip doğadaki fraktal nesneleri tanımlarken fraktal geometri kullanılır. Fraktallerin detayları büyütüldükçe belirginleşir. Detaylı olmasına rağmen tanımlanması kolaydır. Klasik geometrinin tanımlanması formüllerle olurken, fraktal geometri özyineleme metodu kullanır. Öklid geometrisi insan yapımı nesneleri, fraktaller ise doğadaki nesneleri inceler. Fraktallerin özellikleri basit geometrik ifadeler ile tanımlanamaz. Fraktaller basit denklemlerin çözüm kümesi değildir. Fraktallerin büyüklüğü, uzunluk gibi alışılagelmiş ölçülerle tanımlanamaz. Fraktaller, fraktal boyuta sahiptirler ve bu boyut fraktallerin topolojik boyutundan büyüktür [32].

3.2.2. Fraktal Geometri Uygulamaları

3.2.2.1. Von Koch Eğrisi

Von Koch eğrisi çizilirken 3.2'deki gibi bir doğru parçası ile başlanır. Doğru parçası üç eşit parçaya ayrılır ve ortadaki alınır. Ortadaki parça bir eşkenar üçgen şeklinde dışa doğru tamamlanır. Böylece dört eş doğru parçasından oluşan bir kırık çizgi elde edilir. Buna motif veya oluşturucu denir. Eğer ilk doğru parçası 1 uzunluğunda seçilirse, motiflerin her biri uzunluklu dört parçadan oluşur. Dolayısıyla motifin toplam uzunluğu 1/3 olur. Benzer biçimde dört parçadan her birini öncü kabul ederek aynı işlemle birer motif haline getirilir. Böylece Şekil 3.2 elde edilir [33].

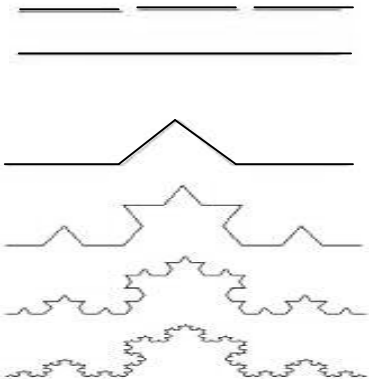

Şekil 3.2. Von Koch [34]

Fraktal boyut: D ile gösterilirse $D=1\backslash N$ ile hesaplanır. Burada N fraktalin oluşumundaki parça sayısını göstermektedir [35].

3.2.2.2. Koch Kartanesi

Koch kartanesi çizilirken, üçgenlere ayrılarak bir kafes biçiminde çizilmiş bir sayfa alınır.

I. Adım: Geniş bir eşkenar üçgen çizilir.

II. Adım: Altı adet sivri köşesi olan bir yıldız elde etmek için:

1. Üçgenin bir kenarı üç eşit parçaya ayrılır ve ortadaki parça alınır.

2. Boşta kalan iki uca alınan bu parçadan birer tane bağlanır ve uçları üçgenin dış tarafında birleştirilir.

3. Bu iş eşkenar üçgenin diğer iki kenarı üzerinde de yapılır. Böylece eşkenar üçgenden altı köşeli bir yıldız elde edilmiş olur.

Ortaya çıkan bu yıldızın sahip olduğu altı eşkenar üçgenin her birinde 2. adım tekrarlanarak ikinci tekrardaki şekil elde edilir. Bu işe devam edilirse çevre uzunluğu sonsuz olan bir grafik elde edilir. Bu halde, Koch kartanesinin ilginç karakteristiği onun çevresidir. Normalde, bir geometrik şeklin çevresi büyütülürse alanı da büyütülmüş olur. Çevresi çok uzun olan bir kare alınırsa alanı da çok büyük olan bir kare alınmış olur [36].

3.2.2.3. Ters Kartanesi

Ters kartanesi fraktal Koch kartanesinin farklı bir şekilde ifade edilmesidir. Ters kartanesinin çizimine Şekil 3.3'de olduğu gibi büyük bir eşkenar üçgenle başlanır. Eğer üçgenlerle kafeslenmiş bir kağıt kullanılırsa üçgenin kenarları 9 kafes uzunluğunda seçilir.

Şekil 3.3. Ters kartanesi [37]

I. Adım: Üçgenin bir kenarı üç parçaya bölünür ve ortadaki parça alınır. Bu parçalardan bir tane daha oluşturulur ve V şeklinde eklenerek, çıkarılan yeni üçgenin içine doğru doldurulur. Üçgenin geri kalan iki kenarına da aynı işlem uygulanır. Böylece bir fırıldak şekli elde edilmiş olur.

II. Adım: Bu metod fırıldakta yer alan yeni üçgenlerle tekrarlanırsa, yukarıdaki şekiller dizisi elde edilir. Bu fraktalin boyutu Koch kartanesininki ile aynıdır [36].

3.2.2.4. Sierpinski Üçgeni

Polonyalı matematikçi Vaclav Sierpinski (1882-1969) 1916 yılında, Sierpinski Üçgeni, Sierpinski Şapkası (Sierpinski Gasket) veya Sierpinski Kalburu (Sierpinski Sieve)'da denilen bir fraktal oluşturmuştur. Bu şeklin bir kilisede süsleme olarak çizili olduğu da bilinmektedir.

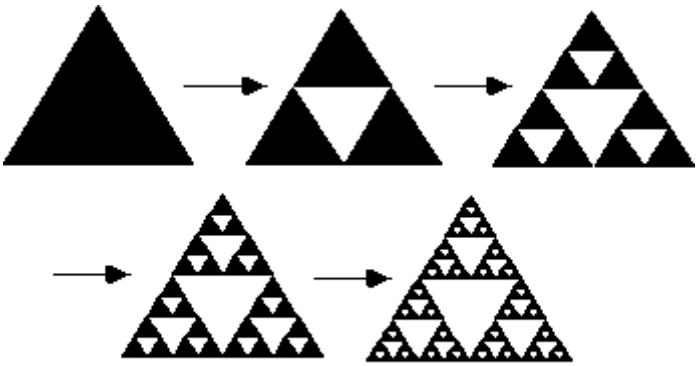

Şekil 3.4. Sierpinski Üçgeni [37]

Şekil 3.4'deki gibi, üçgen olan bir geometrik şekil alınır ve üzerinde daha karışık bir yeni şekil elde edilecek biçimde bir işlem yapılır. Bu işlemi aynen uygulamaya devam edilirse, daha karışık bir şekil elde edilir. Bu işlem tekrar tekrar uygulamaya devam edilirse, yukarıda şekli görünen ve Sierpinski Üçgeni denen fraktal elde edilir.

I. Adım: Kenar uzunluğu 2 birim olan bir eşkenar üçgen çizilir. Her kenarının orta noktaları işaretlenir ve bu orta noktalar birleştirilir. Böylece dört tane yeni eşkenar üçgen elde edilmiş olur. Merkezde kalan üçgen karalanır ve merkezdeki üçgen kesilerek çıkartılır.

II. Adım: Kenar uzunluğu 4 birim olan bir eşkenar üçgen çizilir. Kenarlarının orta noktaları birleştirilir. Elde edilen dört yeni eşkenar üçgenden merkezdeki üçgen birinci adımda olduğu gibi karalanır. Sonra da köşelerde yer alan ve karalanmamış olan üç adet üçgenin her biri aynı işleme tabi tutulur.

III. Adım: Kenar uzunluğu 8 birim olan bir eşkenar üçgen çizilir. Yukarıdaki işlemler aynen tekrar edilerek Sierpinski Üçgen tamamlanır. Benzer şekilde boyama işini yapılır ve boyanmış olanlar kesilip çıkartılır. Böylece 1 adet büyük, 3 adet ortanca ve 9 adet küçük boyanmış eşkenar üçgen oluşur.

IV. Adım: Aynı işlem bir duvar kağıdıyla tekrarlanırsa, yukarıdaki adımlar sırasıyla takip edilerek Sierpinski Üçgeni tamamlanır.

Sierpinski Üçgeni pür matematik alanında bir zihinsel üründür. Benzer şekiller deniz kabuğunda ve hücre çoğalmalarında da görülmektedir [36].

3.2.2.5. Sierpinski Halısı

I. Adım: Kenar uzunluğu 9 birim olan bir kare alınır. Kenarlarının her biri üçer eşit parçaya ayrılır. Karşılıklı olarak bu ayrım noktaları birleştirilir.

II. Adım: Oluşan dokuz eş kareden merkezdeki kesilip çıkarılır.

III. Adım: Geri kalan sekiz eş karenin her biri için aynı işlem tekrarlanır.

IV. Adım: Elde edilen şekle aynı metod tekrar uygulanır.

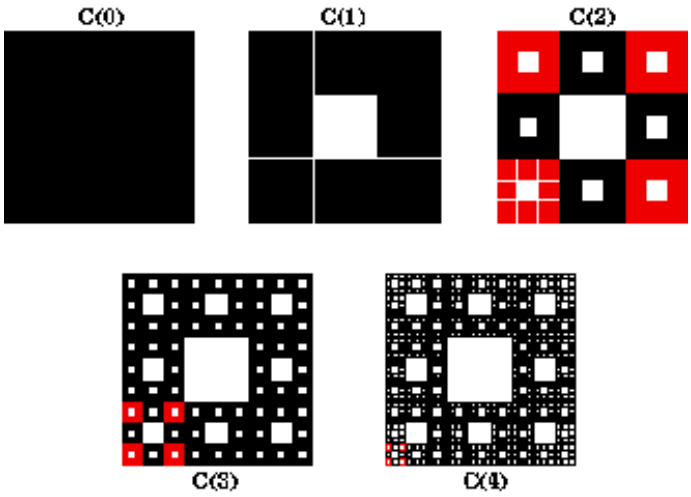

Şekil 3.5. Sierpinski Halısı [38]

Şekil 3.5'de de görüldüğü gibi sonuçta elde edilen şekil çoğu zaman Cantor cümlesinin bir genellemesi olarak görülür [36].

3.3. Fraktallerin Günlük Hayatta Kullanımı

Doğada gizli olan altın oranının bir tam sayıya eşit olmaması, aksine sürekli olarak 1,618'den sonra değişen farklı uzantılara sahip olması nedeniyle, doğada kesirli (fraktal) bir yapı ortaya çıkmaktadır. Doğadaki birçok cisme bakıldığında bu cisimlerin Öklid geometrisi ile ifade edilmesinin mümkün olmayacağı görülür. Örneğin Şekil 3.6'daki natutilus gibi oluşumlar veya şekiller fraktal, yani kesirli geometrilerle birlikte incelenebilmektedir [39-42].

Doğadaki kare, silindir, üçgen, dörtgen gibi matematiksel terimlerle ifade edilmeyen fraktaller sarmal yapıdalardır. Doğada en çok görülen yapılaşma şekli sarmallardır ve altın oran kavramına götüren Fibonacci serisine eşdeğer birçok sarmal yapı mevcuttur. Doğada hem dinamik hem de durağan sarmallar gözlenebilir; örneğin tayfunlar, saman yolu, çam kozalakları, DNA sarmalı gibi [43].

Şekil 3.6. Nautilus [44]

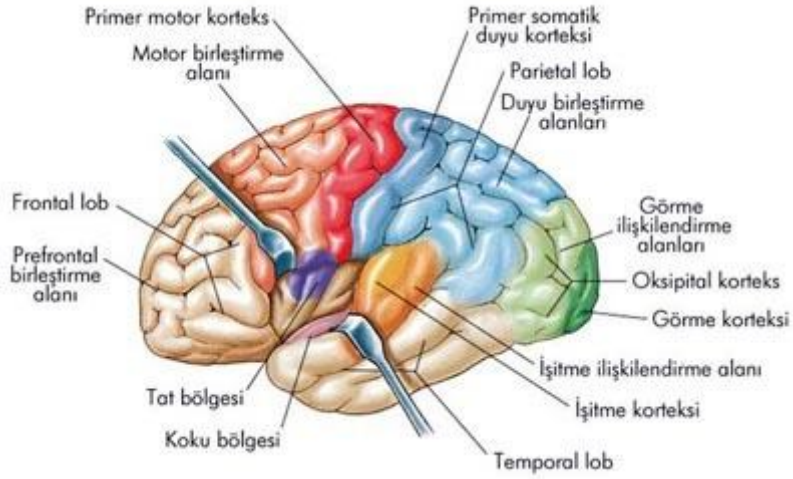

Şekil 3.7. Beyin [45]

Fraktallere başka bir örnek de Şekil 3.7'de olduğu gibi beyin iç yüzeyindeki sarmal, çok sayıda katlanmalardan oluşan ve içe geçmiş katmanlı yapıdır. En gelişmiş canlı kabul

edilen insan beyninin yüzeyi diğer hayvanlara göre daha çok katmalardan oluşur. Beynin yüzeyi diferansiyellenebilir yüzeydir ve fraktal boyutu ikiden büyüktür.

İnsanlarda bu boyut 2,73 ile 2,79 arasında değişir. İnsan anatomisindeki yapıların genelinin fraktal boyutları birer kesirdir.

Kan damarlarındaki kılcallar fraktallere örnek olarak gösterilebilir. Atar damarlar aort ile başlar ve giderek daha küçük kan damarlarına ayrılır. Ayrılarak devam eden bu kanalcıklar, kılcal damarlar denilen daha ince damarlar ile devam eder ve birbirine çok yakın birer gözecikle son bulur. Şekil 3.8'de de görüldüğü gibi bronşlara ait tiplere benzer şekilde kan damarlarında da giderek daha küçük çaplara ayrılmışçasına, şekillenmeler görülmektedir.

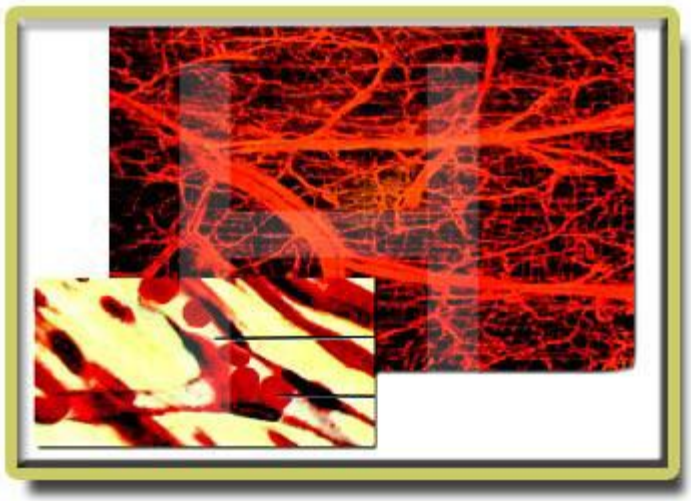

Şekil 3.8. Kılcal damarlar [46]

Fraktaller ilk bakışta karmaşık bir yapı olarak görülebilir. Doğadaki bu oluşumların detayına inildiğinde elde edilen bulgular, bir kaos gibi anlaşılabilir ama karmaşık gibi görülen bu oluşumların aslında yapısında sadelik ve basitlik barındırdığı söylenebilir. Her ne kadar kaosta düzensizlik artsa da, sistemin tümü ya da en küçük parçası kendi içerisinde belli bir düzene sahiptir. Fraktallerin bu kaosu düzensizliğin düzeni şeklinde tanımlanabilir. Şekil 3.9'da Fraktal geometrinin doğada çok sık gözlemlenen bir yaprakta basitten karmaşığa nasıl olduğuna dair örnekler görülmektedir [47, 48].

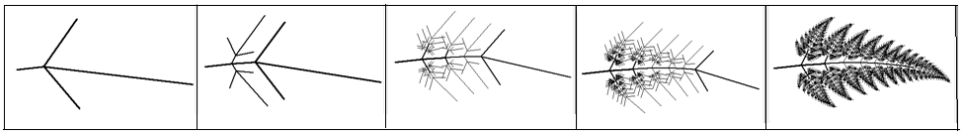

Şekil 3.9. Fraktal geometrinin elde edilmesine dair örnekler [49]

Fraktal geometrinin ortaya çıkışıyla fraktal boyut kavramı bilim adamlarının dikkatini çekmiştir. Kesirli bir boyutun olması, üç boyutlu bir uzayda yaşandığını ve düzlemin boyutunun iki, doğrunun boyutunun bir ve noktanın boyutunun ise sıfır olduğu bilim adamları tarafından kabul edilmektedir. Fraktal geometri kavramını ortaya çıkaran Mandelbrot'a bir iplik yumağının boyutu sorulduğunda yanıtı; "Bu sizin bakış açınıza bağlı bir olay. Uzaktan bakıldığında yumak bir noktadan ibarettir, yani boyutu sıfırdır. Daha yakından yapılan gözlemlerde yumak yüzeyinde düzensizlikler bulunan bir küre gibidir ve boyut sayısı üçe çıkmıştır. Daha yakından bakıldığında ise yumağı oluşturan tek boyutlu iplik ayrık olarak gözlemlenebilir", şeklinde olmuştur [50]. Bu noktada fraktal boyut kavramı ortaya çıkmaktadır. Fraktal, yani kesirli boyut açıklanması zor bir kavramdır [49, 51].

Fraktal geometri istatistik, bilgisayar programcılığı, mimari, fizyoloji gibi birçok alanda kullanılmaktadır. Örneğin; Gökada (yıldız takımları) kümelerinin evrendeki dağılımlarının saptanması, astroidlerin incelenmesi ve bilgisayarda engebeli dağlık arazilerin gerçeğine benzer görüntülerinin oluşturulması gibi [41, 42, 51, 52, 53].

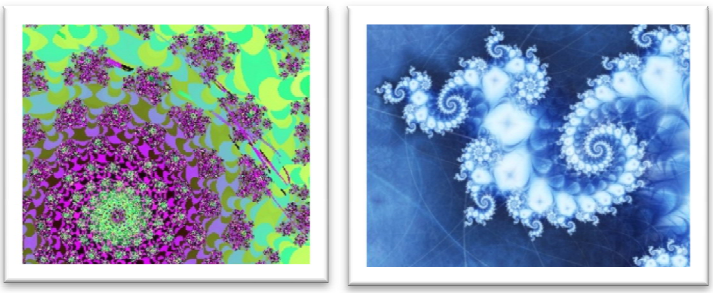

Şekil 3.10. Bilgisayar programlarıyla elde edilen
fraktal örnekler [54]

Doğa, kendiliğinden ölçek değişmezliği gösteren yapıları bir süreçte oluşturmaktadır. Doğadaki mevcut bu sürecin bilim adamları tarafından modellendirilmesi, fraktal şekillerin nasıl oluştuğunu anlamaya yardım etmektedir [55].

Şekil 3.11'de olduğu gibi mimari yapıda da fraktallerin örneklerini görmek mümkündür.

Şekil 3.11. Mimaride fraktaller [56]

Başka bir açıdan doğaya bakıldığında mevcut yapının kesin bir şekilde, sadece *Öklid* geometriye ya da sadece fraktal geometriye uyduğunu söylemek pek de doğru olmaz. Bu durum çok basit bir örnekle açıklanabilir: Doğadaki tuz yataklarındaki tuz (NaCl) kütleleri şekilsiz, girintili çıkıntılı bir yapı sergiler. Bulunduğumuz yerden bakıldığında bu yapının Şekil 3.12'de görüldüğü gibi fraktal geometriye uyduğu söylenebilir. Fakat X-ışını kristalografisi ile daha yakından bakıldığında, kristal yapısının *Öklid* geometrisiyle betimlenen yüzey merkezli kübik bir kristal yapıya sahip olduğu görülür [57].

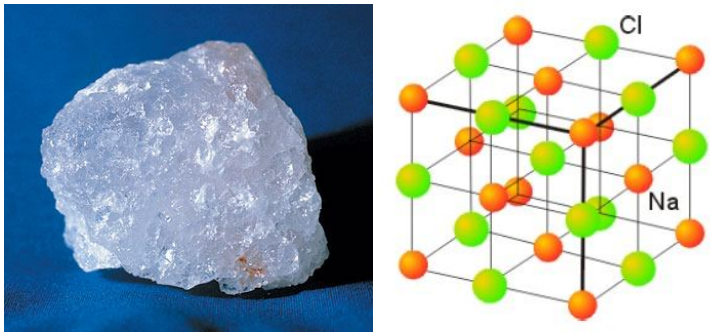

Şekil 3.12. Tuz (NaCl) kütlesi ve kristal yapısı [58]

Fraktal geometri doğadaki çeşitliliğin kavranmasını ve yaşam alanlarındaki değişik boyutlu cisimlerin anlaşılmasını sağlar [59]. Fakat *Öklid* geometrisi de uzayın belli bir kısmı için mükemmel bir gösterim sağlayabilir [60]. Doğa işleyişi bakımından eksponansiyel bir yapı sergiler [57].

3.4. Fraktal Boyut

Fraktal boyut, doğadaki cisimlerde öklid geometrisindeki matematiksel kavramlara karşılık gelmeyen şekilleri tanımlarken ortaya çıkmış bir matemetiksel parametredir. Fraktal boyut cisime bakış açısını değiştirsek de, cismi büyütsek de hep aynı kalan fraktallerin özelliğidir [61]. Eukleidesçi boyutun tersine fraktal boyut, genellikle tam sayı olmayan bir sayıyla, yani bir kesir ile ifade edilir ve bir fraktal eğri yardımıyla anlaşılabilir [62].

Fraktal boyut, bir nesnenin veya olayın biçim, doku, sayı, renk, tekrarlanma, benzerlik, rastsallık, düzenlilik ve heterojenlik gibi özelliklerini tanımlamada kullanılan özellikleri nicelleştirir [63].

Fraktal geometrinin ortaya çıkışı basit uzayın karmaşık alt kümelerinin incelenmesi ile olmuştur. Bir X uzayının elemanları noktaları olan bir küme olarak gösterilirse, metrik uzaya (X, d), X ile birlikte bu uzaydaki x ve y nokta çiftleri arasındaki uzaklıkları ölçen gerçek değerli d fonksiyonundan oluşan bir uzaydır denir. X uzayına Öklid uzayı veya küresel uzay örnek olarak verilebilir. Metrik uzay iki nokta arasındaki uzaklığın Öklid uzaklığı olarak kullanıldığı veya uzaklığın noktalarının apsis ve ordinatları arasındaki farkların mutlak değerlerinin toplanmasıyla bulunduğu Manhattan metrik olabilir. Metrik uzayda yapılan matematiksel dönüşümlerle üretilen ve bu uzayda yer alan karmaşık şekillere fraktal adı verilir [64].

Fraktal boyut kesirli de olabilir veya bir fraktal ölçekten bağımsız herhangi bir eğri, yüzey veya üç boyutlu bir nesne de olabilir. Doğruların boyutu 1, yüzeylerin boyutu 2, katı cisimlerin boyutu 3'tür. Bu çerçevede çok girintili çıkıntılı bir kıyı şeklinin fraktal boyutu 1 ile 2 arasında; daha fazla girintili çıkıntılı bir yüzeyin fraktal boyutu ise 2 ile 3 arasında olacaktır.

L1 ve *L2* kıyı şeklinin birim olarak ölçülen uzunluğu, *s1* ve *s2* ise ölçmede kullanılan ölçeğin büyüklüğü ise bu değerler bir kıyı şekli için;

l1 = 7 ve l2 = 20, *s1=1* ve *s2 = ½* bulunduğunda fraktal boyut:

$$D = \log (l2 / l1) / \log(s2 /s1) = \log(20/ 7)/\log(2)=1,51 \quad \textbf{(3.1)}$$

olarak bulunur [65].

Fraktal boyut uzayda iki nokta arasındaki uzaklığın tanımlanabilir olması temelinden ortaya çıkmış, topolojik olmayan metrik bir kavramdır. Fraktal boyutun temeli *Hausdorff* ve *Besicovitch* tarafından atılmıştır [66]. *Hausdorff-Besicovitch* boyutunun topolojik boyutundan büyük olan kümelere fraktal kümeler denir [67].

Fraktal boyut ve kendine benzerlik arasında önemli bir ilişki vardır. Bir doğru parçası tek boyutludur. Şekil 3.13'de olduğu gibi bir doğru parçası N eşit parçaya bölünerek $r = 1/N$ oranında küçültülebilir [67].

Şekil 3.13. Tek boyutlu nesnede fraktal boyut [67]

Kare gibi iki boyutlu bir objede:

$$r = \frac{1}{\sqrt{N}} \quad \textbf{(3.2)}$$

oranında küçültülerek kare kendine benzeyen N eşit parçaya bölünebilir.

Şekil 3.14. İki boyutlu nesnede fraktal boyut [67]

Üç boyutlu bir küp ise:

$$r = \frac{1}{\sqrt[3]{N}} \quad \textbf{(3.3)}$$

oranında küçültülerek küp *N* küçük kübe bölünebilir [67].

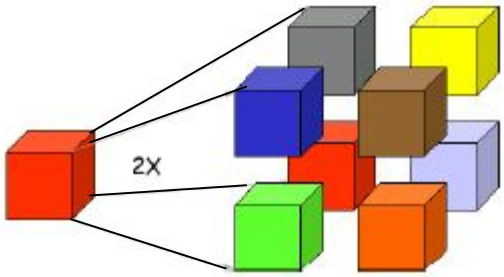

Şekil 3.15. Üç boyutlu nesnede fraktal boyut [67]

Genel olarak *D* boyutlu kendine benzeyen bir nesne:

$$r = \frac{1}{\sqrt[D]{N}} \quad \textbf{(3.4)}$$

oranında küçültülerek *N* tane kendisinin küçük bir kopyası elde edilebilir. Bu ifadeden benzerlik veya fraktal boyut olarak adlandırılan *D* çekilebilir:

$$N = \frac{1}{r^D} \rightarrow D = \frac{\log(N)}{\log\frac{1}{r}} \quad \textbf{(3.5)}$$

Bu şekilde elde edilen *D*, benzerlik ya da fraktal boyut olarak adlandırılır. Fraktal boyut, Öklid boyutundan farklı olarak tam sayı olmak zorunda değildir. Büyüklüğü *r* olan bir oluşumda parçacık sayısı *N*;

$$N \alpha R^d \quad \textbf{(3.6)}$$

bağıntısı ile verilir. Burada *d,* uzayın boyutudur ve oluşumun hacmi de aynıdır.

$$V = A_d R^d \quad \textbf{(3.7)}$$

ile verilir. Burada A_d, geometrik biçimin hesaba katıldığı geometrik çarpandır ve eş eksenli biçim için

$A_1 = 2\pi,$

$A_2 = 4\pi,$

$A_3 = 4\pi/3$

sonuçları ortaya çıkarılabilir [67].

Daha yoğun oluşumlarda $p = N/V$ biçiminde ifade edilen parçacık yoğunluğu, oluşumun büyüklüğünden bağımsızdır [67].

Yoğun olmayan oluşumlar için tamamen farklı bir durum gözlenmektedir. Oluşumun R büyüklüğü artarken denklem 3.8 ile parçacık sayısı çok yavaş artar.

$$NaR^D \qquad \textbf{(3.8)}$$

D üsteli, fraktalin temel nicel karakteristiğidir ve fraktal boyutu denir. D fraktal boyutu, yoğunluk oluşumu için verilen NaR^D bağıntısındaki fiziksel uzayın d boyutundan farklı olduğu için NaR^D bağıntısı anormal bir karaktere sahiptir.

$$(paR^{(d-D)})\backslash d>D \qquad \textbf{(3.9)}$$

Fraktal nesnenin belirginleşmesi d topolojik ve D fraktal boyutları arasındaki farka bağlıdır. Yukarıdaki şekilde verilen fraktalin yoğunluğu, fraktalin yoğun olmayan karakterini yansıtan büyüklüğün azalan bir fonksiyonudur [68].

İngilteredeki sahil şeridi referans alınarak hesaplanan sahil şeridi ölçümlerinde, fraktal boyutun $D > 1$ olduğu bulunmuştur. İngiltere kıyıları için bu sayı 1.3'dür. Elde edilen sonuçlardan sahil şeridinin doğru $(d = 1)$ ve yüzey $(d = 2)$ arasında bir küme olduğu ve $1 < D < 2$ niceliği ne kadar büyükse sahil şeridi o kadar düzenlidir gibi sonuçlar ortaya çıkmıştır [68].

4. YAPAY SİNİR AĞLARI

4.1. Biyolojik Nöron ve Yapay Sinir Hücresi

Bilgisayarlar günlük yaşama girdikten sonra arşivleme, arşive ulaşma, işlem yapma, iletişim gibi pek çok konuda zaman daha verimli kullanılmaya işlemler daha pratik yapılmaya başlandı. İnsanların yaptıkları birçok işi bilgisayarlar artık daha hızlı ve daha az insan gücü ile gerçekleştirebilmektedir. Örneğin arşivden bir dosyanın bulunması belki saatleri bulurken, bilgisayarlar bunu veri tabanı sorgulama sistemleri ile saniyeler içerisinde sonuçlandırıp sonucunu sıfır hata payı ile iletmektedirler. Bilgisayara aritmetiksel ve mantıksal işlemlerin dışında işlem yaptırmak isteyen, yani öğrenmeyi öğretmeyi planlayan bilim adamları, insanların öğrenmesini gerçekleştiren sinir sistemini örnek alarak bilgisayar öğrenmesini gerçekleştirmek için çalışmalara başlamışlardır [69].

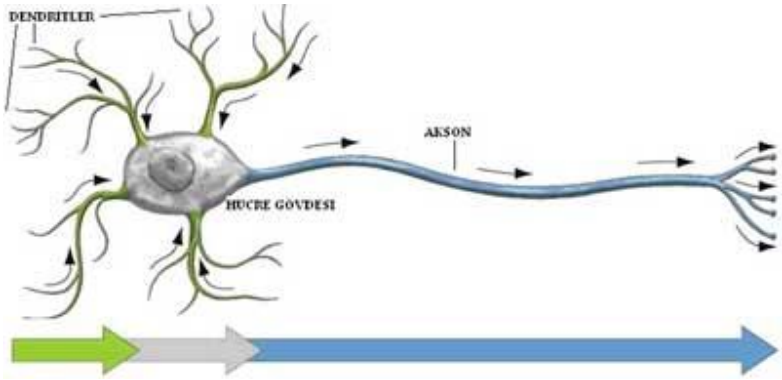

Şekil 4.1. Biyolojik nöron yapısı [69]

Biyolojik sinir sistemindeki Şekil 4.1'de görünen nöronların yapısı, nöronlarla bilginin alınması, elektriksel sinyale dönüştürülmesi, beyinin buna cevap üretmesi ve elektriksel olan bu cevabın yine sinir hücrelerinin yardımıyla organların anlayacağı bir sinyale çevrilmesi,

sinirsel ağ yapısının seri değil de paralel bir şekilde işlemesi, kulağımızın belirli bir frekansın altındaki sesleri duymaması ve tüm sistemin belirli bir eşik değerini geçmeyen olaylara tepki vermemesi, bu sistemlerin oluşmasında bilim adamlarına yön göstermiştir.

Yapay Sinir Ağları (YSA) bilgisayara öğrenme özelliği kazandırmak için oluşmuş sistemlerdir. Herhangi bir olay hakkında girdi çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilme özelliği YSA'lardaki zeki davranışlarında temelini teşkil eder [70].

4.2. Yapay Sinir Ağlarının Genel Yapısı

Biyolojik sinir sisteminde nöronların yerini yapay zekada işlem elemanları, dendritlerin yerini, toplama fonksiyonları, hücre gövdesini transfer fonksiyonu, aksonları çıkışlar ve sinapsların yerini ağırlıklar almıştır ve YSA bunlara bağlı olarak 5 kısımdan meydana gelir.

1. Giriş: Sisteme gelen bilgiler sistemin girişleridir.
2. Ağırlık: Girişlerin sistem üzerindeki etkisini belirler.
3. Birleştirme fonksiyonu: Hücreye gelen bilgiyi net olarak hesaplayan fonksiyondur. Birleştirme fonksiyonu genellikle ağırlık ile girişin çarpımından meydana gelir.
4. Etkinleştirme Fonksiyonu: Birleştirme fonksiyonu ile elde edilen net girdiyi bir işlemden geçirerek işlemin çıkışını bulur. Etkinleştirme fonksiyonu belirli bir değerin altındaki değerleri işlemez. İnsan vücudundaki gibi çalışma prensibi vardır. Örneğin kulağımızla duyduğumuz sesler belirli bir frekans değerinin üstündedir bu frekans değeri ise duymak için bir eşik değeridir. Etkinleştirme fonksiyonu o eşik değerini belirler. Uygun olan fonksiyonu kullanıcı belirler. Etkinleştirme fonksiyonları birkaç şekilde olabilir [71].
5. Çıkış: Etkinleştirme fonksiyonundan geçen sistemin ürettiği çıkışlardır.

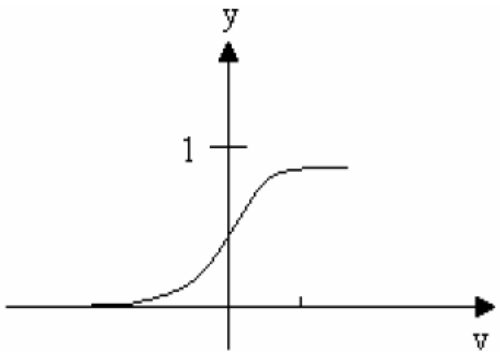

Şekil 4.2. Doğrusal etkinleştirme fonksiyonu [71]

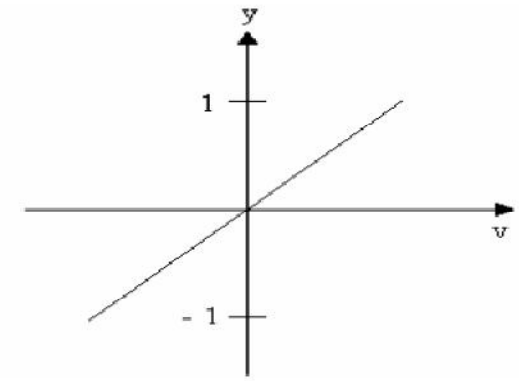

Şekil 4.3. Sigmoid etkinleştirme fonksiyonu [71]

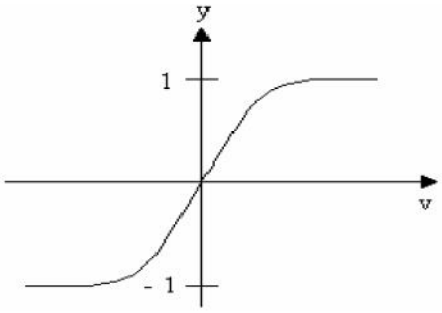

Şekil 4.4. Tanjant hiperbolik etkinleştirme fonksiyonu [71]

YSA yukarıda sayılan kısımlardan Şekil 4.5'deki yapı meydana gelmiştir.

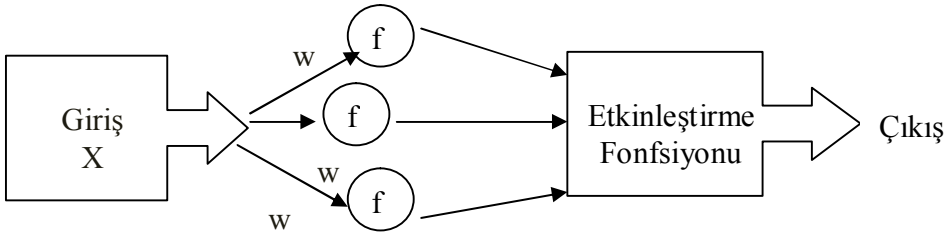

Şekil 4.5. Yapay Sinir Ağ yapısı

YSA sistemlerinin avantajlarını aşağıdaki şekilde sıralanabilir:

- Ağ yapısı birbirine seri olmadığı için bir birimde çıkan sorun tüm sistemi etkilemez, çalışmayı durdurmaz, sadece sistemin yavaş çalışmasına sebep olur, ama sistem muhakkak bir sonuç verir. Yani hataları tolere edebilir.
- Ağda bir görev paylaşımı vardır, her işlem birimi problemin kendine ait olan parçasıyla ilgilenmektedir.
- Doğrusal bir sistem olmadığından, karmaşık sistemlerde daha iyi sonuçlar verir.
- Paralel olarak çalıştığından, hatalı olan alan sistemin çalışmasını durdurmaz.
- Problemi çözmek için örneklerden yararlanır. Önce çözdüğü problemleri öğrenme yoluyla diğer problemlere uygular.
- Önceden çözdüğü problemlere ve öğrenmelere dayanarak genellemeler yapabilir.
- Problemde olan değişikliklere göre kendi sistemdeki bileşenlerini fonksiyonlarını ayarlar.
- Sistem hızlıdır.
- YSA sistemlerinin tasarımı kolaydır.

4.3. YSA Sınıfları

Yapay Sinir Ağları sınıflandırma sistemleri kendi aralarında guruplara ayrılır. Bunlar Şekil 4.6'da gösterilmiştir.

Şekil 4.6. Yapay sinir ağlarının sınıflandırması

4.3.1. Eğiticisiz Öğrenme

Sisteme girişten bilgi verilir ve ağ bu bilgilerden benzer olanları gruplandırır, sistemdeki ağırlıklarını belirler. Giriş olarak verilen bilgilerin çıkıştaki durumlarına bakılarak kendi sınıflamasını kendisi gerçekleştirir. Sistem verdiği cevaplar sayesinde uygun cevabı bulur ve bunu benzer guruplara da uygular. Sistem en uygun cevabı bulana kadar döngü şeklindedir. Şekil 4.7'de kendi kendine öğrenme yapısı gösterilmiştir.

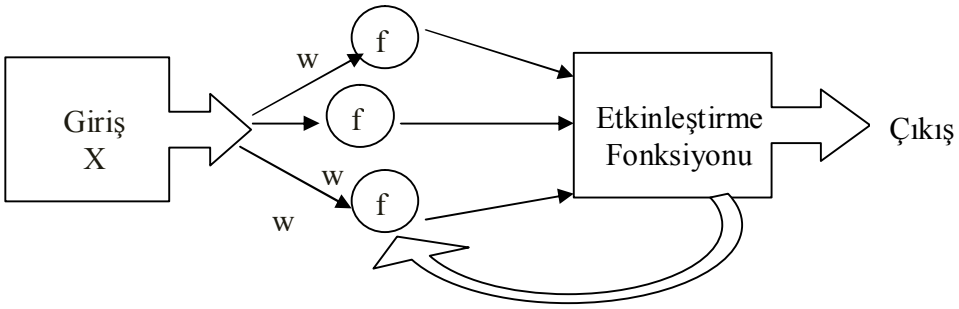

Şekil 4.7. Eğiticisiz öğrenme

4.3.2. Eğiticili Öğrenme

Eğiticili öğrenme moduyla, yapay sinir ağının eğitimi için eğitici veriler (eğitim seti) kullanılmaktadır. Ağın eğitimi için, öncelikle bağlantı ağırlıklarına rasgele değerler atanmaktadır. İstenilen bilgiler ve ağın çıkışı arasındaki fark (hata) azalıncaya kadar eğitim sürdürülmektedir. Ağ çıkışındaki hatanın azalması, ağırlıkların kararlılık kazanması demektir. Ağırlıklar istenilen kararlılığa ulaştığında eğitim bitirilmektedir [72]. Widrow-Hoff tarafından geliştirilen delta kuralı, Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı ve geri besleme algoritması, eğiticili öğrenme algoritmalarına örnek olarak verilebilir [73]. Şekil 4.8'de eğiticili öğrenme yapısı gösterilmiştir.

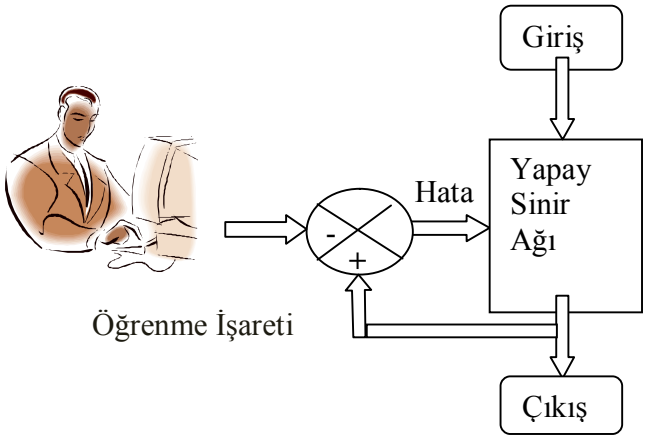

Şekil 4.8. Eğiticili öğrenme

4.3.2.1. Statik Öğrenme

Çok Katmanlı Algılayıcı Modeli:

Statik öğrenme sistemleri arasında Çok Katmanlı Algılayıcı (ÇKA) Modeli, mevcut sinirsel ağ örnekleri arasında en çok bilineni ve en popüler olanıdır [74]. ÇKAYSA için öncelikle algılayıcı modelinin bilinmesinde fayda görülmektedir [75].

Çok Katmanlı Algılayıcı 1950'li yıllarda Rosenblatt tarafından önerilen orijinal algılayıcı modelinin bir çeşididir [76]. Çok Katmanlı Algılayıcı modelinde, bir doğrusal ağırlıklı ağ fonksiyonu ve bir eşik etkinleştirme fonksiyonu bulunan tekli bir nöron bulunmaktadır. Bu nörona giriş vektörü *x=(x1, x2,... , xn)*, *n*-boyutlu uzayda, bir özellik vektörüdür. Ağ fonksiyonu *f(x),* girişlerin ağırlıklı toplamıdır. Bir algılayıcı sinirsel ağ modeli Şekil 4.9'da gösterilmiştir [77, 78]. Matematiksel olarak ise;

$$f(x) = w_0 + \sum_{i=1}^{n} w_i x_i \qquad \textbf{(4.1)}$$

olarak ifade edilir. *y(x)* çıkışı, *f(x)* fonksiyonunun örnek olarak bir eşik etkinleştirme fonksiyonundan geçirilmesi ile şu şekilde hesaplanır;

$$y(x) = \begin{cases} 1, & f(x) \geq 0 \\ 0, & f(x) < 0 \end{cases} \qquad \textbf{(4.2)}$$

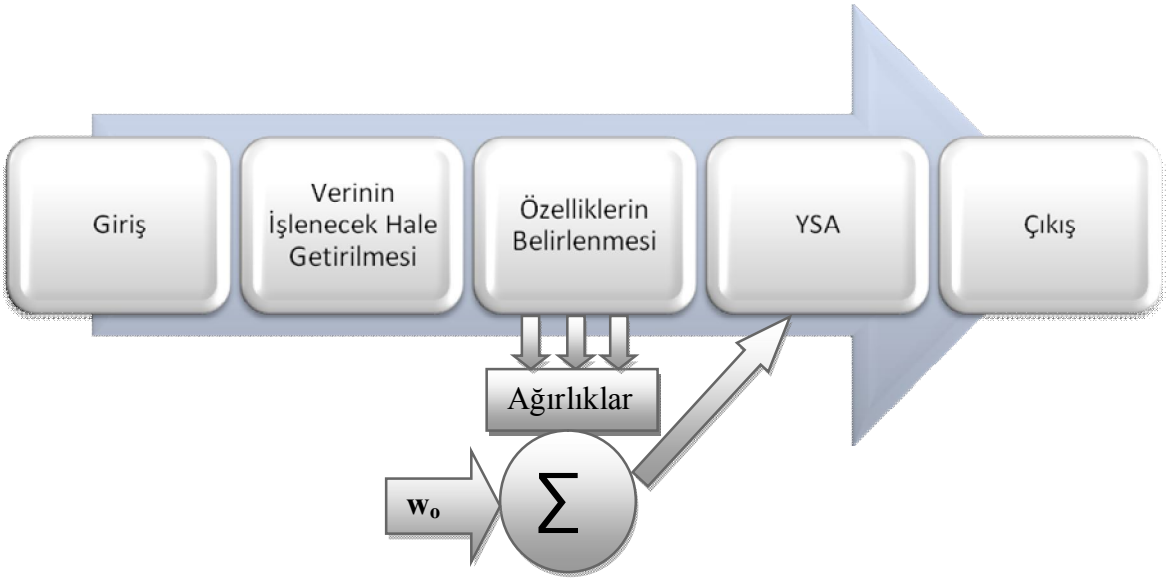

Şekil 4.9. Tek algılayıcı sinirsel ağ modeli

Algılayıcı nöron modeli, tespit ve sınıflandırma için kullanılabilmektedir. Örneğin, ağırlık vektörü $w = (w1, w2,..., wn)$, kesin bir hedef kalıbını hazırlayabilir. Eğer giriş özellik vektörü x'in, bu vektöre karşılık gelen ağırlık vektörü w ile iç çarpımı $-w_0$ eşik değerini aşarsa, o durumda çıkış değeri, $+1$ olacak ve hedefin tespitini gösterecektir. Bir algılayıcı modelini uygulamak için, ağırlık vektörünün hesaplanması gereklidir. Bu hesaplama, eğitme örnekleri ve test örneklerine ihtiyaç duyar. Burada, eğer w ağırlık vektörü doğru seçilirse, $y(x(i))$ fonksiyonu, istenen çıkış değeri için, birbirinden ayrılmış eğitme ve test indekslerine (Ir ve It) sahip olacaktır. Rasgele sıralanmış eğitme örnekleri ile sıralı algılayıcı öğrenme algoritması kullanılarak, w ağırlık vektörünün doğru değerleri hesaplanabilir [75]. Öğrenme algoritmasının matematiksel gösterimi ise,

$$w(k+1)=w(k)+\eta(d(k)-y(k))x(k) \qquad \textbf{(4.3)}$$

şeklinde olacaktır. Burada $y(k)$, Denklem 4.1 ve Denklem 4.2 kullanılarak hesaplanmaktadır [75].

Denklem 4.3'de, öğrenme hızı η $(0 < \eta < 1 / |x(k)|maks)$, kullanıcı tarafından seçilen bir parametredir ki burada, $|x(k)|maks$ eğitme örnekleri $\{x(k)\}$'nın maksimum büyüklüğüdür.

k indeksi ise rasgele bir sıradaki algılayıcıya dizi şeklinde uygulanan eğitme örneklerini göstermek için kullanılmaktadır. Her seferinde bir eğitme örneği uygulanır ve algılayıcının çıkışına karşılık gelen *y(k),* istenen çıkış değeri *d(k)* ile karşılaştırılır. Aynı olmaları durumunda, ağırlık vektörü *w*, bu eğitme örneği için doğrudur anlamına gelirken, ağırlık bundan sonra değişmeyecektir. Diğer bir taraftan, $y(k) \neq d(k)$ olduğu zaman ise, *w* vektörü *x(k)* giriş vektörü doğrultusunda küçük bir adımla tekrar hesaplanmış olacaktır. Eğer eğitme örnekleri, doğrusal olarak ayrılabilir durumda ise, algılayıcı öğrenme algoritması, sınırlı bir sayıda iterasyon yaparak en uygun ağırlık vektörü çözümüne yaklaşım sağlayacaktır. Diğer bir taraftan, eğitme örnekleri doğrusal olarak ayrılabilir değil ise, algoritma sabit bir değerle (η 'nın sıfırdan farklı bir değeri) yakınsama sağlamayacaktır [75].

Algılayıcı modelinin örüntü sınıflandırması ve işaret tespiti çözümlemelerine uygulanmasında birkaç önemli zorluk ortaya çıkmaktadır [77]. Bunlar;

1. Kendine has özellikleri bulunan *x* vektörünü çıkaracak olan doğrusal olmayan dönüşüm belirli değildir.
2. Eğer eğitme özellik yapısı doğrusal olarak ayrılabilen değilse, algılayıcı öğrenme algoritması, *η* öğrenme oranının sabit bir değeri için yakınsama yapmayacaktır.
3. Özellik yapısının doğrusal ayrılabilir olmasına rağmen, özellik yapısını ayıran bir hiper düzleme karşılık gelen ağırlık vektörüne yakınsama yapılabilmesi için oluşturulacak algoritmanın ne kadar zaman alacağı bilinmemektedir.

Bir Çok Katmanlı Algılayıcı Sinir Ağı Modeli, McCulloch ve Pitts nöronlarının ileri beslemeli ve katmanlı olarak yapılmış bir ağ yapısından oluşmaktadır. ÇKA'daki her nöron, sürekli olarak türevi alınabilen doğrusal olmayan bir etkinleştirme fonksiyonuna sahiptir. ÇKA yapısında, sık kullanılan etkinleştirme fonksiyonlarından bazıları sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Üç katmanlı bir algılayıcı sinir ağı Şekil 4.10'da gösterilmiştir. Şekil üzerindeki her bir daire tek bir nöronu ifade etmektedir. Bu nöronlar, giriş katmanı, gizli katman 1, gizli katman 2 ve çıkış katmanı olarak adlandırılan katmanlar ile organize olurlar [75].

Böylece, ÇKA girişi ve çıkışı arasında doğrusal olmayan bir eşleşme sağlanmaktadır.

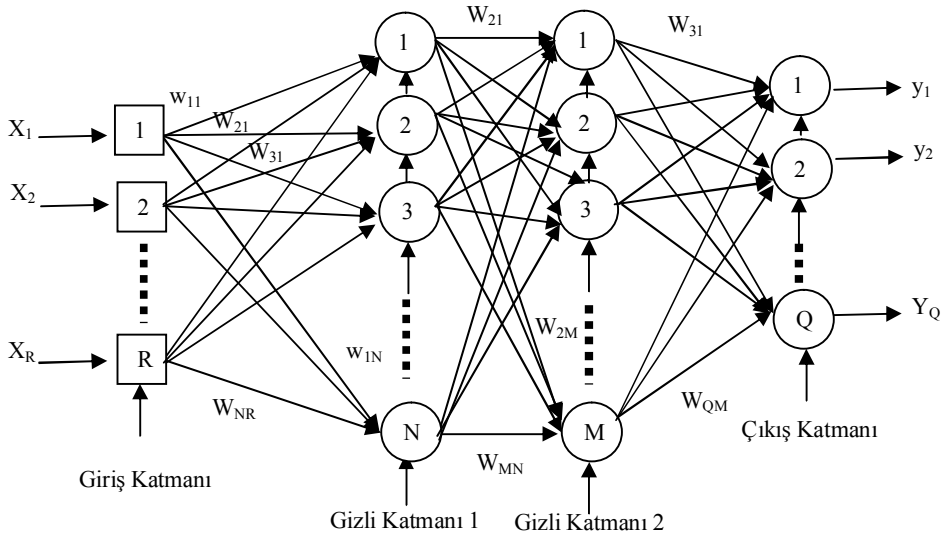

Şekil 4.10. Üç katmanlı algılayıcı sinir ağı örneği [75]

Bir ÇKA modelini uygularken atılacak önemli adımlardan biri ağırlık matrisinin seçilmesidir. Bir ÇKA yapısı varsayıldığında, nöronların her katmanına karşılık gelen ağırlıklar, o katmanın ağırlık matrisini oluşturmaktadır (Giriş katmanı nöron içermiyorsa bir ağırlık matrisine sahip değildir). Bu ağırlıkların değerleri, geri yayılım eğitme hata yöntemi ile bulunmaktadır. Hata yöntemleri ile ilgili geniş bilgi ekte yer almaktadır. Bu yöntemlerden Levenberg-Marquardt algoritması en uygun geri yayılım eğitme hata yöntemidir [75].

ÇKYSA modeli danışmanlı öğrenme yöntemini kullanmaktadır [79]. Ağa hem girişler hem de bu girişlere karşılık gelen hedef çıkışlar verilmektedir. Ağ kendisine gösterilen örneklerden genellemeler yaparak problem uzayını temsil eden bir çözüm uzayı üretmektedir [80]. Bu amacı gerçekleştirmek için ÇKYSA modelinde, öğrenme algoritması olarak en küçük kareler yöntemine dayanan Delta Kuralının genelleştirilmiş hali kullanılmaktadır. Bu sebeple öğrenme algoritmasına, genelleştirilmiş delta kuralı veya hatanın geriye yayılma algoritması (Error Backpropagation) denilmektedir. Bu algoritmaya göre ağın eğitilebilmesi için eğitim seti ve bu sete karşılık ağın üretmesi gereken hedef çıkış seti olmalıdır. Eğitim seti içinde sınıfları temsil eden segmentler her segmentte de veriyi temsil eden ve ağın girişini oluşturacak örnekleri içerir [80, 81].

Bir ÇKYSA modelinin hatanın geriye yayılması yöntemine göre eğitilmesi üç adımda gerçekleştirilir: Giriş eğitme verisinin ileriye doğru yayılması, verilen hedef değerlerine

karşılık hatanın hesaplanması ve bu hatanın geriye doğru yayılarak ağırlıkların ayarlanması [80, 82, 83].

Eğitme başlamadan önce ÇKYSA modeli için öncelikle eğitim seti ve hedef çıkış seti belirlenir. Maksimum iterasyon sayısı, gizli düğüm sayısı, öğrenme oranının ve en küçük hata kriterinin değerleri tanımlanır. Eğitim için kullanılacak segment sayısını eğitim setinin sütun sayısı belirler. Giriş katmanı nöron sayısı, eğitim setinin satır sayısı yani her bir segmentteki örnek sayısı ile otomatik olarak tanımlanmış olur. Çıkış katmanı nöron sayısı ise hedef setinde bulunan herbir segmentin örnek sayısı ile tanımlanır. Daha sonra giriş, gizli ve çıkış katmanında bulunan nöronlar arasındaki bütün bağlantı ağırlıklarına ve eşik ağırlıklarına rasgele küçük değerler atanır [80, 81].

1. Adım: İleriye doğru yayılma

İleriye doğru yayılma adımı giriş katmanından çıkış katmanına doğru nöronların giriş ve çıkış değerlerinin, hatanın geriye yayılma algoritmasına göre hesaplandığı adımdır. Bu adımda, öncelikle eğitim setinin bir segmenti $(x_1, x_2,..,x_m)$ ve bu segmentin ağda işlenmesinden sonra ağın üretmesi beklenen hedef çıkış segmenti $(d_1, d_2,..,d_p)$ ağa sunulur. Giriş katmanına uygulanan giriş değerleri hiçbir işlem uygulanmadan gizli katmana iletilir. Gizli katmanda bulunan bir nöron, giriş katmanından gelen bilgileri bağlantı ağırlıklarının etkisi ile kabul eder [80, 81, 82]. Gizli katmanda bulunan herhangi bir *i.* nöronun ağırlıkları girişlerinin toplamı dikkate alınarak Denklem 4.4'deki gibi hesaplanabilir [75].

$$I_j(u) = \sum_{i=1}^{t} w_{ij} O_i(u) + \theta_j \qquad \textbf{(4.4)}$$

Burada *t,* bir önceki katmanda bulunan düğüm sayısı, w_{ji} *j.* nöronun bir önceki katmanda bulunan *i.* nöron arasındaki bağlantı ağırlığının değeri, O_i bir önceki katmanda bulunan nöron çıkışı ve θ_j eşik elemanın ağırlık değeridir. Bir nöronun ağırlıklı toplamı elde edildikten sonra O_j nöron çıkışını bulmak için nöron etkinleştirme fonksiyonuna $(\psi(.))$ uygulanır [75].

$$O_j(u) = \psi\left(I_j(u)\right) \qquad \textbf{(4.5)}$$

Bu şekilde ağ üzerinde önce gizli katmanda ve sonra çıkış katmanında bulunan bütün nöronların ağırlıklı giriş değerleri I_j ve nöron çıkış değerleri O_j sırasıyla Denklem 4.4 ve Denklem 4.5 ile hesaplanır [75].

2. Adım: Hatanın hesaplanması ve geriye yayılması

Bu adımda, ağın ürettiği çıkış ile olması beklenen çıkış arasındaki fark bütün nöronların eğimlerine yansıtılır. Bunun için, ağa sunulan giriş segmenti için ağın ürettiği çıkış $(O_j(u))$ ile bu segment için ağa gösterilen hedef çıkış değeri $(d_j(u))$, çıkış katmanındaki nöronlar için karşılaştırılır. Aradaki fark, $e_j(u)$, u. segment için j. çıkış nöronundaki hata değerini ifade eder (Denklem 4.5). Toplam hatayı bulmak için eğitme setinde bulunan bütün segmentler için e_j hatalarının toplanması gerekir. Bazı hata değerlerinin negatif olma ihtimaline karşı ağın toplam hatasını bulmak için Denklem 4.6 ile ifade edilen toplam karesel hata hesaplanır. Eğitimin amacı da ağ parametrelerini ayarlayarak, toplam karesel hata değerini en aza indirmektir [75].

$$e_j(u) = d_j(u) - O_j(u) \tag{4.6}$$

$$E = \frac{1}{2}\sum_{u=1}^{n} e_j(u)^2 \tag{4.7}$$

Çıkış katmanında bulunan bütün nöronlar için hata $(e_j(u))$ bulunduktan sonra ağırlıkların güncellenmesi için gerekli eğim değerleri çıkış katmanından gizli katmana doğru hesaplanır. Çıkış katmanında bulunan j. nöronun eğim değeri δ_j, karesel hatanın nöron girişine göre birinci türevi alınarak bulunur [83]. Çıkış katmanındaki bir nöron için eğim, δ_j, nöronun e_j hata değeri (Denklem 4.10) ve etkinleştirme fonksiyonunun $(\psi(.))$ türevi (Denklem 4.11) ile hesaplanır (Denklem 4.12).

$$\delta_j = -\frac{\partial E}{\partial I_j} \tag{4.8}$$

$$\frac{\partial E}{\partial I_j} = -\frac{\partial E}{\partial O_j}\frac{\partial O_J}{\partial I_J} \tag{4.9}$$

$$\frac{\partial E}{\partial O_j} = \frac{\partial E}{\partial e_j}\frac{\partial e_j}{\partial O_j} \quad \textbf{(4.10)}$$

$$\frac{\partial O_j}{\partial I_j} = \psi'(I_j) \quad \textbf{(4.11)}$$

olur. Buna göre çıkış katmanındaki *j.* nöronun eğimi Denklem 4.12 ile ifade edilebilir.

$$\delta_j = e_j \psi'(I_j) \quad \textbf{(4.12)}$$

Çıkış katmanındaki bütün nöronlar için eğim hesaplandıktan sonra, gizli katman nöronların eğim hesabı yapılır. Bunun için çıkış katmanında bulunan nöronlarda olduğu gibi, Denklem 4.8'den faydalanılır. Gizli nöron için Denklem 4.8 aşağıdaki şekilde açılır. Gizli katmanda bulunan herhangi bir nöronun ÇKYSA mimarisine göre çıkış katmanındaki bütün nöronlarla bağlantısı vardır. Bu nedenle herhangi bir gizli katman nöronunun eğimini hesaplarken çıkış katmanındaki bütün nöronlardan etkilenmektedir [75].

$$\frac{\partial E}{\partial I_j} = -\sum_{i=1}^{p} \frac{\partial E}{\partial I_i}\frac{\partial I_i}{\partial I_j} \quad \textbf{(4.13)}$$

Burada p çıkış katmanında bulunan nöron sayısını I_j, gizli katman nöronunun girişini ve I_i ise çıkış katmanı nöronunun girişini ifade etmektedir.

$$\frac{\partial I_i}{\partial I_j} = \frac{\partial I_i}{\partial O_j}\frac{\partial O_i}{\partial I_j} \quad \textbf{(4.14)}$$

Denklem 4.13 ve Denklem 4.14 ile gösterilen kısmi türevler alındığı zaman, gizli katmanda bulunan nöronlar için eğim ifadesi Denklem 4.15'de olduğu gibidir.

$$\delta_j = \psi'(I_j)\sum_{i=1}^{p}(\delta_i W_{iJ}) \quad \textbf{(4.15)}$$

Burada δ_i çıkış katmanındaki *i.* düğümün eğimi ve W_{ij} çıkış katmanındaki *i.* nöron ile gizli katmandaki *j.* nöron arasındaki bağlantı ağırlığıdır. Denklem 4.15'de görüldüğü gibi gizli katmandaki nöronların eğimi için öncelikle çıkış katmanındaki nöronların eğim değeri ile bağlantı ağırlıklarının çarpımlarının toplamı bulunarak, gizli katmandaki nöron etkinleştirme fonksiyonunun türevi ile çarpılır [75].

3. Adım: Ağırlıkların Güncellenmesi

Bu adımda ise gizli katmanda ve çıkış katmanında bulunan nöronların eğim değerlerine bağlı olarak önce giriş katmanı ile gizli katman arasındaki ağırlıklar, daha sonra gizli katman ile çıkış katmanı arasındaki ağırlıklar güncellenir. Yeni ağırlık değerini bulabilmek için önceki değer ile ağırlıktaki değişim miktarına ihtiyaç vardır (Denklem 4.16). Ağırlık değerindeki değişimi bulmak amacıyla karesel hata *E*'nin ağırlığa *(w)* göre birinci türevi alınır (Denklem 4.17) [82, 83].

$$W_{ji}^{s+1} = W_{ji}^{s} + \beta \Delta W_{ji} \tag{4.16}$$

$$\Delta W_{ji} = -\frac{\partial E}{\partial W_{ji}} \tag{4.17}$$

$$\frac{\partial E}{\partial W_{ji}} = -\frac{\partial E}{\partial I_J}\frac{\partial I_j}{\partial W_{ji}} \tag{4.18}$$

w_{ij}^{S} , ağırlık değeri

w_{ij}^{s+1}, ağırlıkların alacağı yeni değeri

β öğrenme oranı

$\Delta\, w_{ij}$ olması gereken değişimi ifade eder ve Denklem 4.19'daki gibi bulunur.

$$\Delta\, w_{ij} = \delta_j O_i \tag{4.19}$$

Nöronun eşik değeri ise nöronlar arasındaki bağlantı ağırlık değerleri ile aynı şekilde hesaplanır.

$$\theta_{ji}^{s+1} = \theta_{ji}^{s} + \beta\Delta\theta_{ji} \quad \textbf{(4.20)}$$

$$\Delta\theta_{ji} = -\frac{\partial E}{\partial \theta_{ji}} \quad \textbf{(4.21)}$$

$$\frac{\partial E}{\partial w_{ji}} = -\frac{\partial E}{\partial I_j}\frac{\partial I_j}{\partial \theta_{ji}} \quad \textbf{(4.22)}$$

Böylece Denklem (4.16 - 4.17) arasındaki eşitlikler kullanılarak bağlantı ve eşik ağırlık değerleri değiştirilir. İleriye doğru yayılma fazıyla başlayıp ağırlık ve eşik güncellemesiyle sona eren üç aşamanın tamamına bir "çevrim" adı verilir. Bir çevrim boyunca, ağın girişine uygulanan eğitim veri segmenti ağırllıkların değerlerine ve nöronlarda bulunan etkinleştirme fonksiyonuna göre Denklem 4.4 ve 4.5 kullanılarak ileriye doğru yani giriş katmanından başlayarak çıkış katmanının nöron çıkışları hesaplanıncaya kadar yayılır. Daha sonra ise çıkış katmanından elde edilen nöron çıkış değerleri, olması gereken çıkış değerleriyle karşılaştırılır. Buradan elde edilen fark bütün ağa geriye yayılma adımıyla çıkış katmanından giriş katmanına doğru yansıtılır ve bütün nöronlar için eğim değerleri hesaplanır. Hesaplanan bu eğim değerlerine göre ağırlıkların değerleri güncellenir [75].

Bir sonraki çevrimde, ağın girişine eğitme setinin ve hedef çıkış setinin bir sonraki segmenti sunularak, ileriye doğru yayılma adımından başlanır. Bundan sonra eğitme setinin her segmenti için bu işlem tekrarlanır. Eğitme setinin tamamı için bilgi işleme aşaması tamamlandığı zaman bir "iterasyon" oluşmuş demektir [82]. Eğitimin amacı, giriş segmentine karşılık ağın ürettiği çıkış değerlerinin, hedef çıkış değerleriyle aynı olmasını sağlamaktır. Bunun için de Denklem 4.7 ile verilen karesel hata değerinin, eğitme başlamadan önce verilen en küçük hata değerinden daha küçük olmasını sağlamak yani hatayı minimize etmektir [75].

Yukarıdaki anlatılan adımlar, ÇKYSA ağının eğitilmesi tamamlanıncaya kadar devam eder. Diğer bir deyişle elde edilen ağ çıkışları ile hedeflenen ağ çıkışları arasındaki hata kabul edilebilir düzeye ininceye kadar tekrar ettirilir. ÇKYSA modellerinde, maksimum iterasyon sayısı ve kabul edilebilir hata değeri (minimum hata kriteri) durdurma kriteri olarak belirlenmiştir. Eğer ağ maksimum iterasyon sayısına ulaşmamışsa, her iterasyon sonunda

hesaplanan karesel hata değeri minimum hata kriteri ile karşılaştırılarak öğrenmenin gerçekleşip gerçekleşmediğine bakılır [75].

Ağın eğitiminin tamamlanması, ağ girişine uygulanan verilere karşılık gelecek uygun çıkışı üretmesini sağlayan ağırlık değerlerinin bulunduğu anlamına gelmektedir [80]. Eğitimi tamamlandıktan sonra ağın başarısını ölçmek için test veri seti kullanılmaktadır.

Öğrenmeli Vektör

Şekil 4.12'de görüldüğü üzere 3 kattan oluşan Öğrenmeli Vektör Ağı girdi ve saklı kat arasında tamamen, saklı ve çıktı kat arasında kısmen bağlılık arzeder. Her çıkış neronu farklı bir saklı nöron kümesine bağlıdır [84].

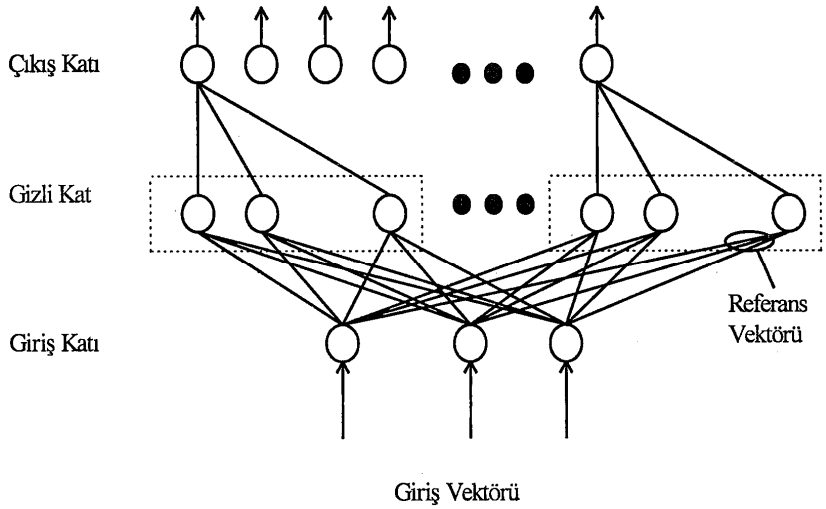

Şekil 4.11. Öğrenmeli vektör [84]

4.3.2.2. Dinamik Öğrenme

İleri Beslemeli

İleri beslemeli bir ağda işlem elemanları (İE) genellikle katmanlara dağılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İE'ler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları

bulunmaz. İleri beslemeli ağlara örnek olarak ÇKA ve LVQ (Learning Vector Quantization) ağları verilebilir [85].

İleri beslemeli YSA'da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta katmandaki hücrelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapısı ile ileri beslemeli ağlar, doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli 3 katmanlı YSA'nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir. En çok bilinen geriye yayılım öğrenme algoritması, bu tip YSA'ların eğitiminde etkin olarak kullanılmakta ve bazen bu ağlara geriye yayılım ağları da denilmektedir. Şekil 4.13'de giriş, orta ve çıkış katmanı olmak üzere, 3 katmanlı ileri beslemeli YSA yapısı verilmiştir [73].

$$\mathrm{net}_j^a = \sum A_{kj}\, Ç_k^i \qquad \textbf{(4.23)}$$

A_{kj}, *k.* girdi katmanı elemanını *j.* ara katman elemanına bağlayan bağlantının ağırlık değeridir. *j.* ara katman elemanının çıktı değeri ise, *net* girdinin etkinleştirme fonksiyonundan geçirilmesi ile elde edilir. Herhangi bir problemi çözmek amacıyla kullanılan YSA da, katman sayısı ve orta katmandaki hücre sayısı gibi kesin belirlenememiş bilgilere rağmen nesne tanıma ve sinyal işleme gibi alanların yanı sıra, ileri beslemeli YSA, sistemlerin tanımlanması ve denetiminde yaygın olarak kullanılmaktadır [72].

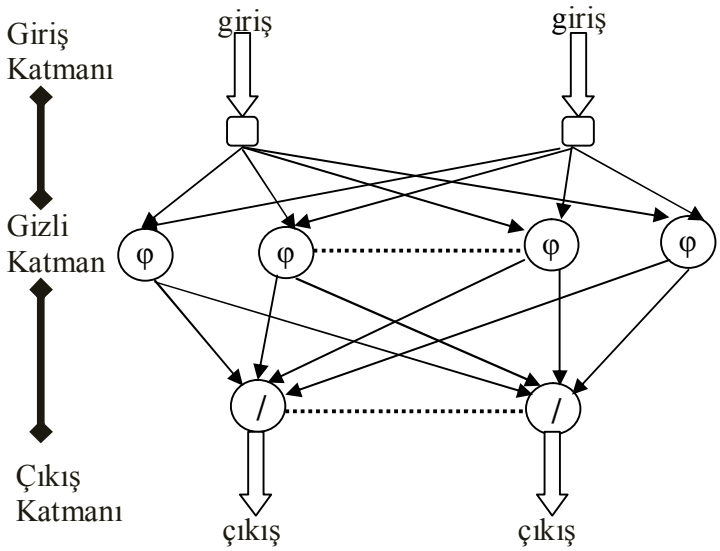

Şekil 4.12. İleri beslemeli 3 katmanlı yapay sinir ağı [72]

Geri Beslemeli

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 4.14'de bir geri beslemeli ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundurlar. Geri beslemeli ağlar çeşitli tipteki zaman serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map – Özörgütlemeli Haritalar), Elman ve Jordan ağları verilebilir [85].

Geri beslemeli YSA'da, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli YSA yapıları elde edilebilir.

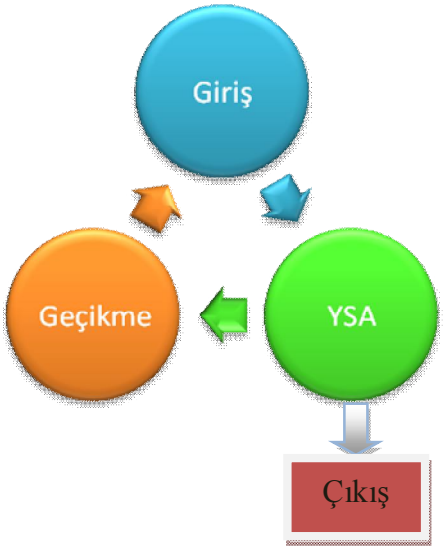

Şekil 4.13. Geri beslemeli ağ için blok diyagram

Geriye doğru hesaplamada, ağın ürettiği çıktı değeri, ağın beklenen çıktıları ile kıyaslanır. Bunların arasındaki fark, hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Çıktı katmanında *m.* işlem için oluşan hata, *Em* = *Bm* - *Çm* olacaktır [85].

Çıktı katmanında oluşan toplam hatayı bulmak için bütün hataların toplanması gereklidir. Bazı hata değerleri negatif olacağından, toplamın sıfır olmasını önlemek amacıyla ağırlıkların kareleri hesaplanarak sonucun karekökü alınır. Toplam hata aşağıdaki formül ile bulunur [85].

$$\text{Toplam Hata} = \frac{1}{2}\sum_{m} E_m^2 \qquad \textbf{(4.24)}$$

Toplam hatayı en aza indirmek için, hatanın kendisine neden olan işlem elemanlarına dağıtılması gerekmektedir. Bu da işlem elemanlarının ağırlıklarını değiştirmek demektir [73].

4.3.3. Takviyeli Öğrenme

Eğiticili öğrenmeye yakın bir modeldir. Eğiticili öğrenme ile arasındaki fark öğretmen yerine deneme yanılma yöntemi ile çıkışın uygun olup olmadığını değerlendirir. Uygun çıkış bulunana kadar sistem deneme yanılma yöntemi ile işlemleri tekrarlar. Çıkış bulunduktan sonra ağırlıklar ona göre ayarlanır. Bu yöntemin en güzel örneği genetik algoritmadır. Bunda girişe uygun çıkışın ne olduğunun bilinmesine gerek yoktur [86].

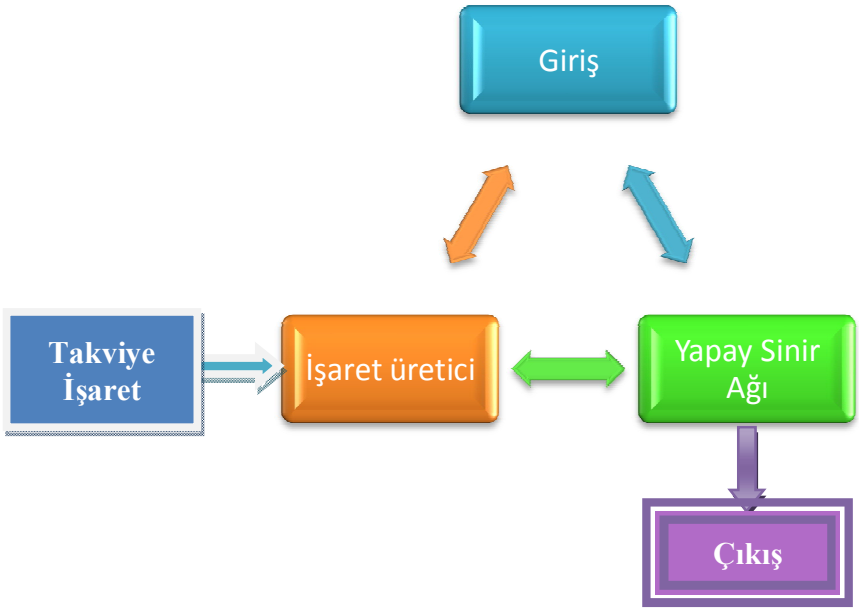

Şekil 4.14. Takviyeli öğrenme yapısı

5. DOPPLER KALP SES İŞARETLERİNİN SINIFLANDIRILMASI

Biyomedikal işaret işleme ile hastalık teşhis sistemleri geliştirilirken işaret üç ayrı aşamadan geçirilir. Bu aşamalar aşağıdaki Şekil 5.1'de genel olarak gösterilmiştir.

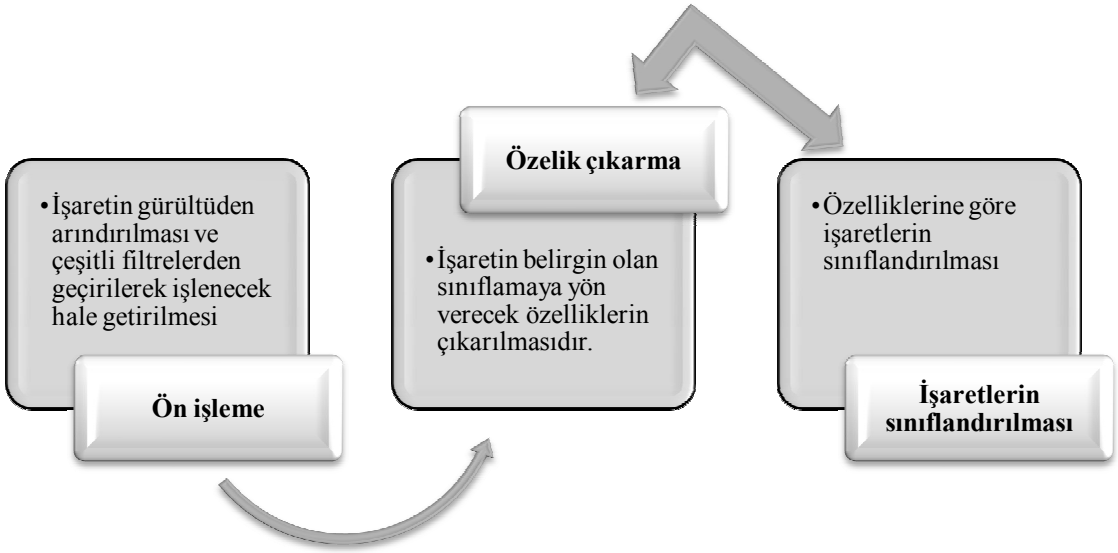

Şekil 5.1. İşaret sınıflama aşamaları

İşaret elde etme, bozucu etkenlerin yok edilmesi, ortalama alma, eşik değeri belirleme, işaret iyileştirme gibi işlemler ön işlemeyi oluşturmaktadır. Özelik çıkarma, şekil tanımlama ve şeklin önemli özeliklerinin çıkarılıp özellik vektörünün elde edilmesi işlemidir. Özellik seçme isteğe bağlı olarak yapılan bir işlem olup sınıflama işlemi açısından en belirleyici özelliklerin seçilmesi ile özellik vektörünün boyutunun azaltılmasıdır. Teşhis sistemlerinin son aşaması olan sınıflamada, kullanılan algoritmaya bağlı olarak giriş özellik vektörleri incelenir ve sınıflama sonucu belirlenir. Özellik çıkarma ve özellik seçme sınıflama sonucunu belirlemesi açısından ele alındığında, YSA gibi sınıflama sistemlerinin başarısını oldukça etkilemektedir [87, 88].

Tezde doppler ultrason cihazından elde edilen kalp mitral kapak doppler ses işaretlerinin analizinde bu aşamalar dikkate alınarak Şekil 5.2'deki işlem basamakları oluşturulmuştur. Amaç, fraktal boyut hesaplama yöntemiyle özellik çıkaran bir sistem

oluşturmak ve elde edilen sınıflandırma başarım oranını [7]'deki çalışmada özellik çıkarmada kullanılan entropi hesaplama yöntemiyle kıyaslamaktır.

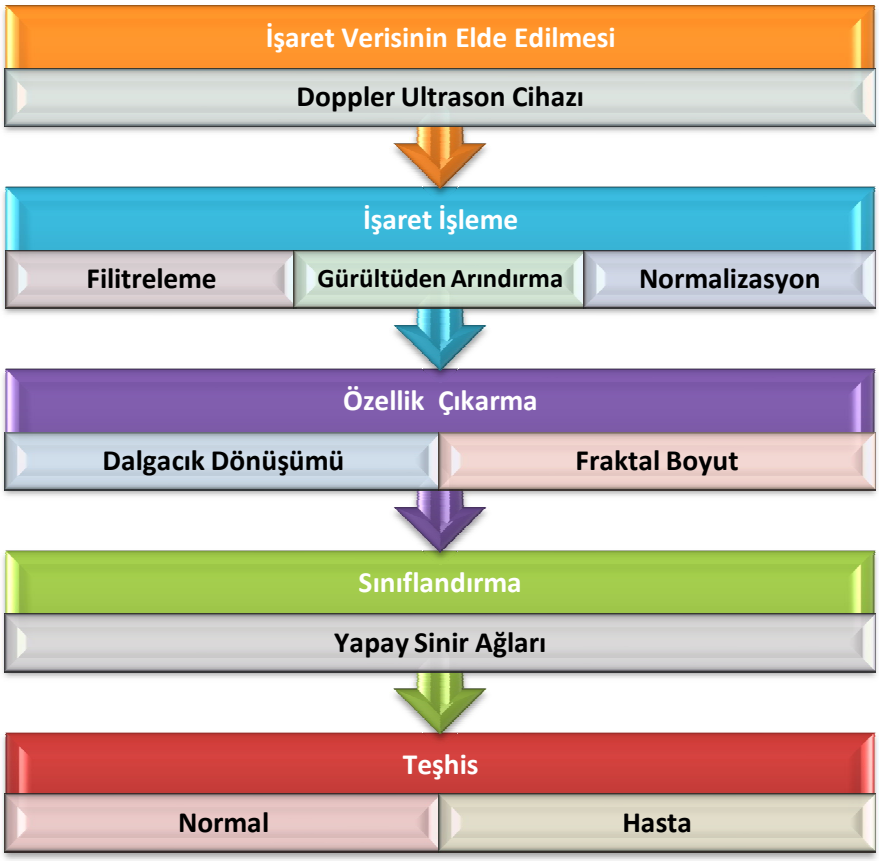

Şekil 5.2. Doppler kalp ses işaretlerinin sınıflandırma süreci

5.1. İşaretin Elde Edilmesi

Renkli Doppler ve Ultrasonografi cihazı; diyabet ve hipertansiyon hastalıklarında böbreği besleyen damarların düzeyini, atar ve toplar damarlardaki kireçlenmeyi (damar sertliği), pıhtı oluşumlarını, toplar damarlardaki yetmezlikleri (varis), siroz gibi hastalıklarda karaciğeri besleyen damarlardaki değişiklikleri, boyundaki beyne giden ana atar damardaki darlıkları, beynin arka kesimini besleyen damarların akım miktarını, hipertansiyonu olan gebelerdeki kan akım hızını ve özelliğini, erkeklerde testisleri besleyen damarlarda meydana gelen ve kısırlığa yol açabilen düzensiz genişlemeleri, vücudun herhangi bir yerindeki tümörü besleyen damarların durumunu tespit etmekte

yararlanılmaktadır. Bu cihaz hastanın incelenen organı üzerine jel sürerek ve jel üzerine probları yerleştirerek kullanılır [89].

Vücudumuzda sürekli düzgün bir hareketin en belirgin olduğu yer damarlardır. Bu nedenle doppler öncelikle damar incelemesinde kullanılan bir yöntemdir. Hemen tüm damarlar dopplerle incelenebilir. Doppler ultrasonografide kan damarına gönderilen ses dalgası ve yansıyarak geri dönen ses dalgasının frekansı arasındaki fark değerlendirilerek, kan akım hızı ve kalp atışlarıyla bu hızda ortaya çıkan değişiklikler saptanabilir [90].

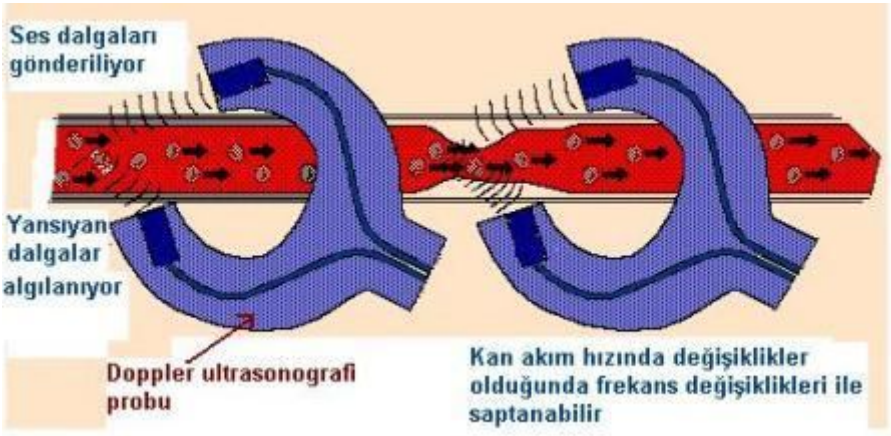

Şekil 5.3. Doppler ultrasonografi çalışma prensibi [90]

C = Sesin ortamdaki hızı (m/s)
Vrbc = Kan akım hızı (m/s)
Θ = Akımın yönü ile ultrason ışını arasındaki açı
Fo = İletilen ultrason frekansı (Hz)
Fr = Geri dönen ultrason frekansı (Hz)

FD = Frekansdaki Doppler kayması
= Fo - Fr
=Fo.2(Vrbc.CosΘ)/C **(5.1)**

FD.Vrbc = (C.FD)/(Fo.CosΘ) **(5.2)**

Orijinal DKS (Doppler Kalp Ses) işaretleri, Fırat Tıp Merkezi Kardiyoloji kliniğinde, Acuson Sequoia 512 Model Doppler Ultrason cihazından alınmıştır. *Vpp = 1* voltluk çıkış genliğine sahip, cihazın Doppler ses çıkışından DKS işaretleri MATLAB ortamında geliştirilen bir yazılımla, 5 saniyelik olarak, işaretin gürültü seviyesi *SNR = 0* dB kazançlı ve 20 kHz 'lik örnekleme frekansı ile 16-bitlik A/D çözünürlüğüne sahip olan bir ses kartı üzerinden bilgisayara sayısal biçimde ve hekim gözetiminde alınmıştır. Kullanılan Doppler ultrason transdüserinin (Model 3V2c) çalışma modu 2 MHz sürekli dalgadır. Her bir kalp kapağına ait DKS işareti ultrason görüntüsü yardımı ile trandüser hastanın göğsü üzerinde uygun yere yerleştirilerek, 58 hasta 35 sağlam insanlardan işaretler elde edilerek, kayıt alınmıştır. Şekil 5.4'de yetmezlik (Şekil 5.4a) ve normal (Şekil 5.4b) olan kişilerden alınan doppler işareti görülmektedir.

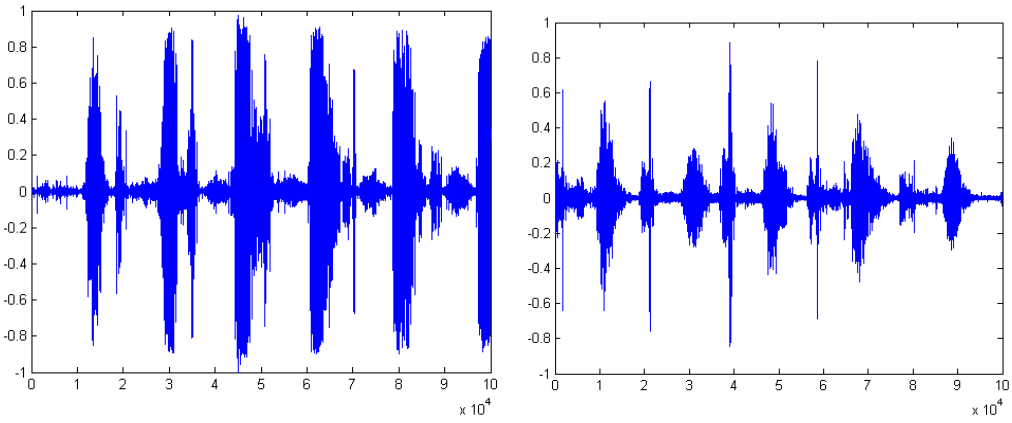

a)Normal **b)**Yetmezlik

Şekil 5.4. Hasta ve sağlıklı kişilerden alınan doppler işareti

5.2. Ön İşlem Süreci

Elde edilen işaretin arzu edilen işaret haline dönüştürülmesi için 3 ön aşamadan geçirilmesi gerekmektedir. Böylelikle dışarıdan gelen etkilerin işaret üzerindeki etkileri azaltılır ve sistem daha kararlı hale getirilir. İşaret işleme, işareti daha uygun bir şekle dönüştürüp, işaretden gürültüyü temizleyerek veri spektrumu elde etmede kullanılır [91].

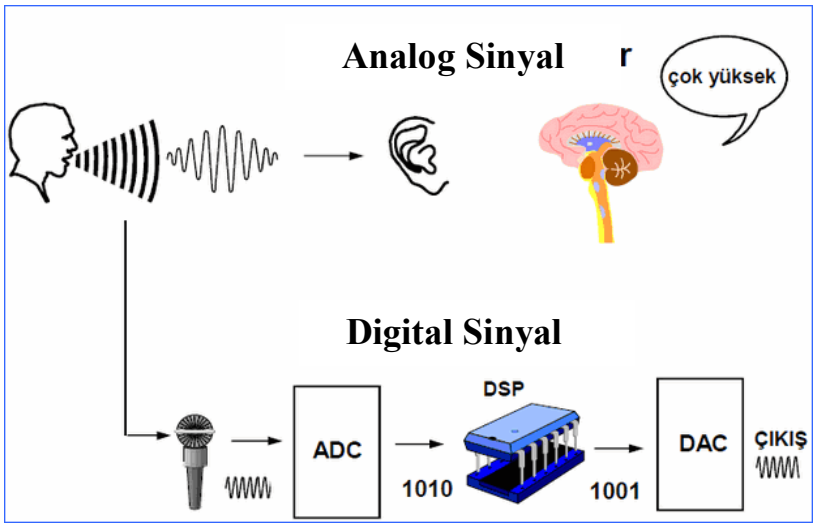

Şekil 5.5. İşaretin işlenmesi [91]

5.2.1. Filtreleme

Filtre, elde edilen işaretin dış etkilerden kurtarılıp işlenebilecek işaret haline getirilmesi işlemidir. Sayısal filtreler işaret işlemede ve onun uygulamalarında çok önemli bir yer tutar. Sayısal filtrelerin amacı, elde edilmesi gereken işareti diğer işaretlerden süzmektir. Sayısal filtreler darbe cevabına göre ikiye ayrılır. FIR filtre sonlu darbe cevaplı, IIR ise sonsuz darbe cevaplı filtredir. FIR filtrelerde çıkış, girişin o andaki ve daha önceki değerlerine bağlı olup, çıkışın değerine bağlı olmayan tekrarsız filtredir [85].

Sayısal filtre tasarımında temel amaç filtrenin özellikleri hakkında bilgi veren transfer fonksiyonundaki katsayıların hesaplanması işlemidir. Transfer fonksiyonundaki katsayıların farklı tiplerde seçilmesi işlemi ile tasarlanan filtre modeli de alçak-geçiren, yüksek-geçiren, band-geçiren ve band-durduran gibi değişmektedir [93].

FIR filtrelerin sadece sıfırları olup, kutupları olmadıklarından daima kararlı, önceden belirlenmiş genlik ve faz cevabını sağlayacak şekilde lineer fazlı olarak tasarlanabilmeleri avantajdır. FIR filtrelerin dezavantajı ise, istenilen özellikleri sağlayan bir IIR filtreden daha yüksek derecede gerçekleştirilmeleridir [94]. FIR filtre tasarımı, Fourier serisi yöntemi ve frekans örneklemesi yöntemi olmak üzere iki şekilde yapılmaktadır [95].

FIR filtrenin transfer fonksiyonu;

$$H(z) = \sum_{n=0}^{n=1} h(n) z^{-n} \quad \textbf{(5.3)}$$

Matlab da filtreleme işlemleri için hazır fonksiyonlar bulunmaktadır. FIR filtresi için kullanılan komut aşağıda belirtilmiştir [95].

B=Fir1(N,Wn) genel biçimine sahip bu komut pencere yöntemini kullanarak FIR filtrenin katsayılarını (*N+1* adet) hesaplar [95]. Burada;

N: Filtrenin derecesi, 50 olarak seçilmiştir.

Wn: Filtrenin kesim frekansı. Değeri *0<Wn<1* arasında değişmektedir. 1 değeri Nyquist frekansına yani örnekleme frekansının yarısına karşı gelmektedir. Eğer *Wn* tek elemanlı ise filtre geçirme bandı *0<W<Wn* olan alçak geçiren filtre olmaktadır. Eğer *Wn=[W1 W2]* şeklinde iki elemanlı bir vektör ise, filtre geçirme bandı *W1<W<W2* olan band geçiren filtre olmaktadır. Bu komut ile yüksek geçiren filtre tasarlamak için komut *B=Fir1(N,Wn,'high')* biçimine getirmek gerekmektedir [95].

$$W[k] = 0.54 - 0.46.\cos\left(2\pi\frac{k}{n-1}\right) \quad k=0,\ldots..n\text{-}1 \quad \textbf{(5.4)}$$

$$W[n] = \begin{Bmatrix} W[k] & 0 \le n \le N-1 \\ 0 & \text{diğer} \end{Bmatrix} \quad \textbf{(5.5)}$$

Fir1 komutu aksi belirtilmediği sürece pencere fonksiyonu olarak Hamming'i kullanmaktadır [95]. Bu komut Matlab programında aşağıdaki şekilde kullanılır.

Hamming(M): M noktalı Hamming penceresi oluşturur.

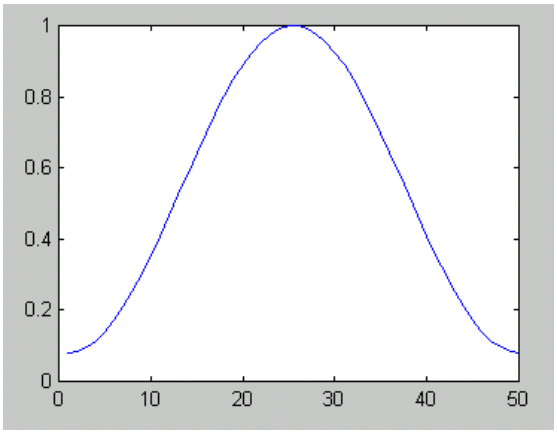

Şekil 5.6. Hamming penceresi

FIR filtreleme ve hamming pencereleme tekniklerinin Matlab ortamında sisteme uygulanması ile sistem gürültüden arındırılmış oldu.

5.2.2. Gürültü Ayrışımı

İşaret içerisindeki gürültüyü temizleme, belirlenen bir kesim frekansından büyük bileşenleri sıfırlayan bir filtreme ile yapılır. Her ne kadar gürültü bileşenlerinin büyük bir kısmı önemli ölçüde azaltılsa da, eğer gürültü işaretin frekans bandında ise bu filtre yöntemi etkisiz kalmaktadır [7].

Beyaz gürültü ayrışımı için üç aşamalı bir sistem geliştirilmiştir. İlk aşamada Daubechies-10 dalgacık filtreleri kullanılarak dalgacık paket ayrışımı yapılmıştır. cd_1'den cd_{12}'ye 12 detay katsayısı ve 1 adet son seviye için ca_{12} yaklaşık katsayı elde edilmiştir. Bu katsayılar eşikleme yöntemi ile belli bir seviyenin altındaki değerler yok edilmiştir. Son olarak dalgacık ayrışımının katsayıları ile DKS işareti yeniden elde edilmiştir.

5.2.3. Normalizasyon

DKS işaretleri Denklem 5.6. kullanılarak normalize edilmiştir. Böylece, işaretin genliğinin hastanın göğüs kafesinin fizyolojik yapısından etkilenmesi ihmal edilecek seviyeye çekilmiştir [7].

$$DKS = \frac{DKS}{|DKS[n]|_{maksimum}} \quad (5.6)$$

5.3. Özelliklerin Çıkarılması

Şekil 5.7. Dalgacık dönüşümü ve fraktal boyut ile özelliklerin çıkarılması

5.3.1. Dalgacık Dönüşümü

Son yıllarda dalgacık dönüşümü analizi, doppler işaretinin zaman ve frekans bölgesi karakteristiklerinin tanımlanmasında kullanılan en verimli yöntemdir. Dalgacıkların bu sistemin kullanımında artan bir eğilim gözlenmiştir. Bu alanlar arasında görüntü işleme teknikleri, tıbbi uygulamalar, radar, akustik, sonar sistemleri, veri sıkıştırma gibi alanlar sayılabilir. Dalgacık dönüşümü yöntemiyle yani zaman-frekans bölgesi yöntemiyle geç potansiyellerin saptanması, doppler işaretinin tüm özelliklerinin saptanmasında, doppler gürültünün süzülmesinde ve işaretin sıkıştırılmasında oldukça başarılıdır. İşaretini oluşturan bileşenleri dalgacık dönüşümü analizi ile çok kolay bir şekilde saptanabilinmektedir.

Ayrıştırma sonucunda oluşan, yüksek frekanslı katsayılar ayrıntı ve düşük frekanslı katsayılara yaklaşım denilir [7]. Daubechies-10 dalgacık filtreleri kullanılarak DKS işaretleri için $m = 12$ seviyede dalgacık dönüşüm ayrışımı yapılmıştır. Her bir ayrışım seviyesi için detay katsayıları $cD = [cd1, cd2, ..., cd12]$ ve 1 adet son seviye için yaklaşık katsayı $ca12$ elde edilmiştir. Şekil 5.8'de bir DKS işaretinin 12 seviyeli dalgacık dönüşümü görülmektedir.

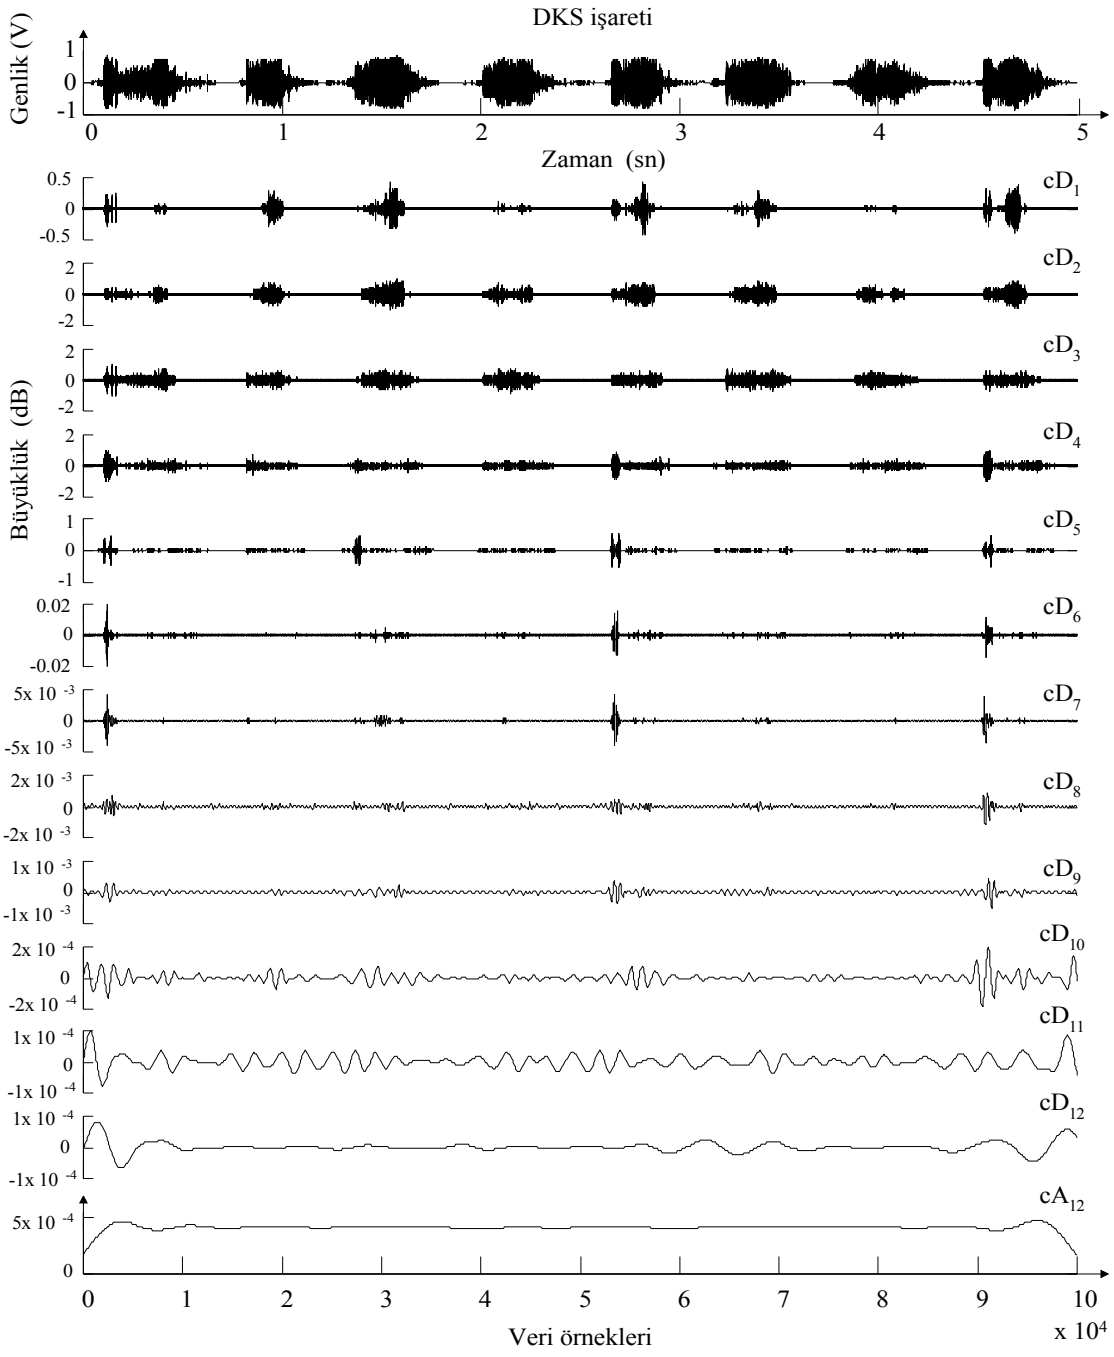

Şekil 5.8. DKS işaretinin dalgacık dönüşüm ağacında bulunan işaretleri

5.3.2. Fraktal Boyutun Hesaplanması

Fraktal boyut biçim, rastsallık, doku, renk, tekrarlama düzensizlik sayı ve benzerlik gibi bir nesnenin veya olayın özelliklerini tanımlamada kullanılan özellikleri nicelleştiren

metrik bir kavramdır. Bölüm 3'deki denklemlere bakılarak *D* boyutlu bir nesne *N* eşit parçaya bölünürse fraktal boyutunu bulmak için denklem 5.10 kullanılır.

$$r = 1 \backslash \sqrt[D]{N} \tag{5.10}$$

D boyutlu bir nesne *r* oranında küçültülerek kendinin bir kopyası elde edilir. Bu ifadeden fraktal boyut çekilirse;

$$D = \log(N) \backslash \log(1 \backslash r) \tag{5.11}$$

bulunur.
Bu formülü daha da genelleştirilirse;

$$D = \log(N) / \log(1/a) \tag{5.12}$$

Formülde; *D* fraktal boyut, *N* fraktal oluşumunda parça sayısı, *a* her parçanın uzunluğunu ifade etmektedir.

Doppler Ultrasondan elde edilen işaretler durağan değildir. Fraktal boyutun kullanımı, benzer veya farklı özelliğe sahip örüntülerin belirlenmesi açısından önemli kolaylıklar sağlamaktadır. İşaret, yüzey taraması ve özellikle finansal değerlendirmeler gibi sistemlerde "Hurst Exponent" yöntemi fraktal boyutun bulunmasında tercih edilir. Genellikle tek boyutlu sistemlerin fraktal boyutlarını hesaplamada kullanılır. Bu fraktal boyutun hesaplanması için bir katsayı üretir ve fraktal boyuttaki değişim;

FB=2-H ile bulunur.

Tek boyuttaki sistemlerde Hurst üstel katsayısı, zaman serilerinin sınıflandırılması amacıyla kullanılan istatistiksel bir ölçüttür. Hurst üstel katsayısı 0 ve 1 aralığında değerler almaktadır. Hurst Exponent ise ;

$$H = \lim_{t_2 - t_1 \to 0} \left(\frac{\log[\mathrm{Var}(s(t_2 - t_1))]}{2 \log(t_2 - t_1)} \right) \tag{5.13}$$

formülü ile bulunur. Fraktal boyutun topolojik boyuttan farkı kendi kendine benzer bir küme olmasındandır. Elde edilen sonuçların tamsayı olması zorunlu değildir.

Tablo 5.1'de Şekil 5.8'de gösterilen DKS işaretinin 13 işaret bileşeninin Hurst Exponent katsayılı fraktal boyut hesaplamaları verilmiştir. Bu değerler bir DKS işaretinin özellik verktörünü oluşturmaktadır. Bu özellikler, sınıflandırma işlemi yapılmadan bir anlam ifade etmemektedir. Bir sonraki adımda elde edilen bu özellikler YSA ile sınıflandırma işlemine tabi tutulmuştur.

Tablo 5.1. Bir DKS için hurst exponent ile hesaplanan fraktal boyutlar

DD İşaretleri	Normal bir DKS işareti	Anormal bir DKS işareti
cd1	-0.0205	-0.2905
cd2	-0.0435	-0.0914
cd3	-0.1239	0.0192
cd4	0.0754	0.1073
cd5	0.0927	0.0974
cd6	0.1938	0.1468
cd7	0.2940	0.1022
cd8	0.3169	0.1371
cd9	0.4654	0.4398
cd10	0.6232	0.6210
cd11	0.7733	0.7718
cd12	0.7972	0.7929
ca12	0.7665	0.7578

5.4. Sınıflandırma

5.4.1. Yapay Sinir Ağları

Doppler ultrason cihazı ile elde edilen işaretler toplamda 93 tanedir. Bunların 58 tanesi kalp yetmezliği olan hastaya 35 tanesi ise sağlam kişilere aittir. Sınıflandırma yapılmasının amacı, hastalık teşhisi için tasarlanan sistemin başarı yüzdesini bulmak ve

çalışma [7]'de aynı işaretlerden entropi yöntemi kullanılarak elde edilen sonuçların başarımı ile Fraktal Boyut hesabı kullanarak elde edilen sonuçları karşılaştırmaktır.

Sınıflandırma yapmak için yapay sinir ağlarının geri beslemeli ağ türü kullanılmıştır. Bu ağda bilginin akışı ileri yönlüdür. Öğrenme ve eğitme algoritması olarak genelde türeve dayalı geriye yayılım algoritması kullanılmaktadır.

Geri yayınım algoritması, bilgi ileriye doğru akarken, hatalar geriye doğru çıkıştan girişe azalarak yansımasından dolayı bu ismi almıştır. Geri yayılmalı öğrenme kuralı, ağ çıkışındaki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Nöronlar (işlem elemanları) katmanlar şeklinde organize edilmiştir. Her bir katmanda en az bir nöron bulunur. Bir önceki katmandaki tüm nöronlar bir sonraki katmandaki nöronlara bağlantı içermektedir. Bu şekilde arzu edildiği kadar katman oluşturulabilir. Bir geri yayınımlı ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte, problemin özelliklerine göre gizli katman sayısını artırabilmek mümkündür. Fakat literatürde kabul gören giriş, ara katman sayısını artırmak yerine, ara katmandaki nöron sayısının artırılmasıdır [7].

Giriş katmanı; giriş veri gruplarının ağa sunulduğu terminallerdir. Bu katmanda nöron sayısı, giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır. Burada giriş verileri, ağırlıklar üzerinden bir sonraki katman olan gizli katmana aktarılır [96].

Gizli (ara) katman; ağın temel işlevini gören katmandır. Bazı uygulamalarda ağda birden fazla gizli katman bulunabilir. Gizli katman sayısı ve katmandaki nöron sayısı, probleme göre değişir. Bu katman; giriş katmanından aldığı ağırlıklandırılmış veriyi probleme uygun bir fonksiyonla işleyerek bir sonraki katmana iletir. Bu katmanda gereğinden az nöron kullanılması giriş verilerine göre daha az hassas çıkış elde edilmesine sebep olur. Aynı şekilde gerektiğinden daha çok sayıda nöron kullanılması durumunda da aynı ağda yeni tip veri gruplarının işlenmesinde zorluklar ortaya çıkabilmektedir [96].

Çıkış katmanı; YSA'nın en uç ve son katmanıdır. Gizli katmandan aldığı veriyi ağın kullandığı fonksiyonla işleyerek çıktısını verir. Çıkış katmanındaki nöron sayısı, ağa sunulan her verinin çıkış sayısı kadardır. Bu katmandan elde edilen değerler YSA'nın söz konusu problem için çıkış değerleridir. Bir geri yayınımlı ağ modelinde; bir katmandan bir başka katmana, aradaki katmanı atlayarak geçebilmek mümkün değildir [96].

YSA'nın eğitimi ve test işlemlerinde 2 katlı çapraz geçerlilik testine dayalı başarı kriteri kullanılmıştır. Buna göre YSA eğitim verileri ile eğitilmiş, test verileri ile test edilmiştir. Bu süreçte YSA'nın eğitim başarımı Şekil 5.9'da gösterilmiştir.

Sonraki aşamada, YSA test verileri ile eğitilmiş, eğitim verileri ile test edilmiştir. Bu süreçteki YSA'nın eğitim başarımı ise Şekil 5.10'da görülmektedir. Sistemin ezber değil, öğrenmeyi gerçekleştirdiği Şekil 5.9 ve 5.10'daki grafiklerden izlenebilmektedir.

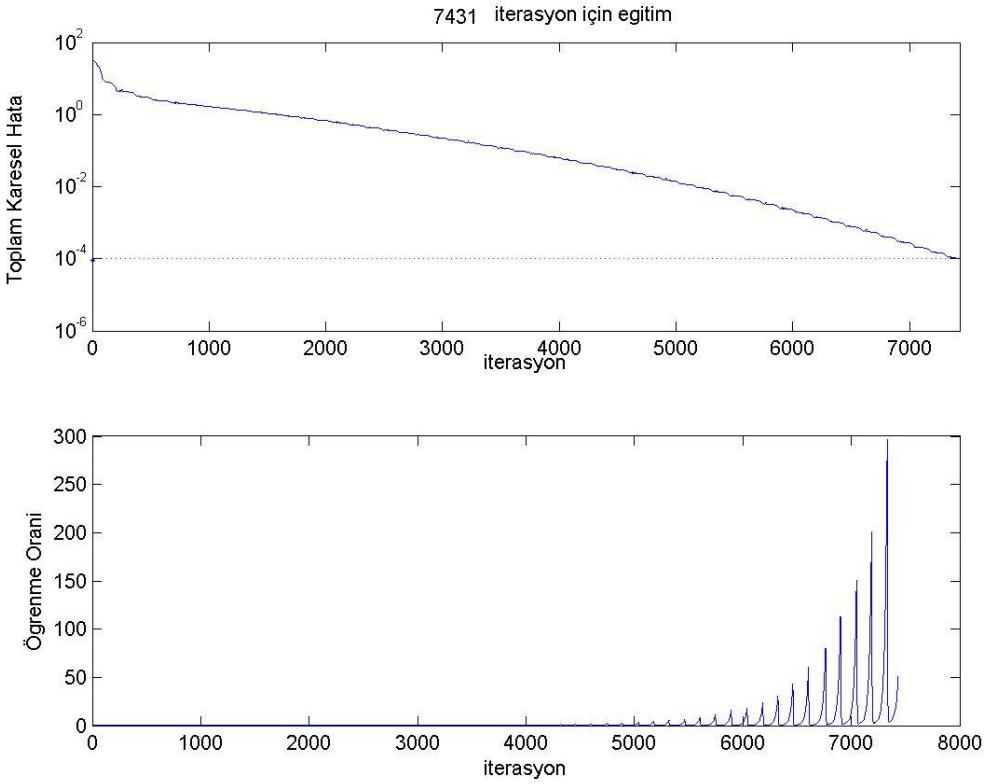

Şekil 5.9. YSA eğitim başarımı – I (Eğitim veri seti ile YSA eğitilmiştir)

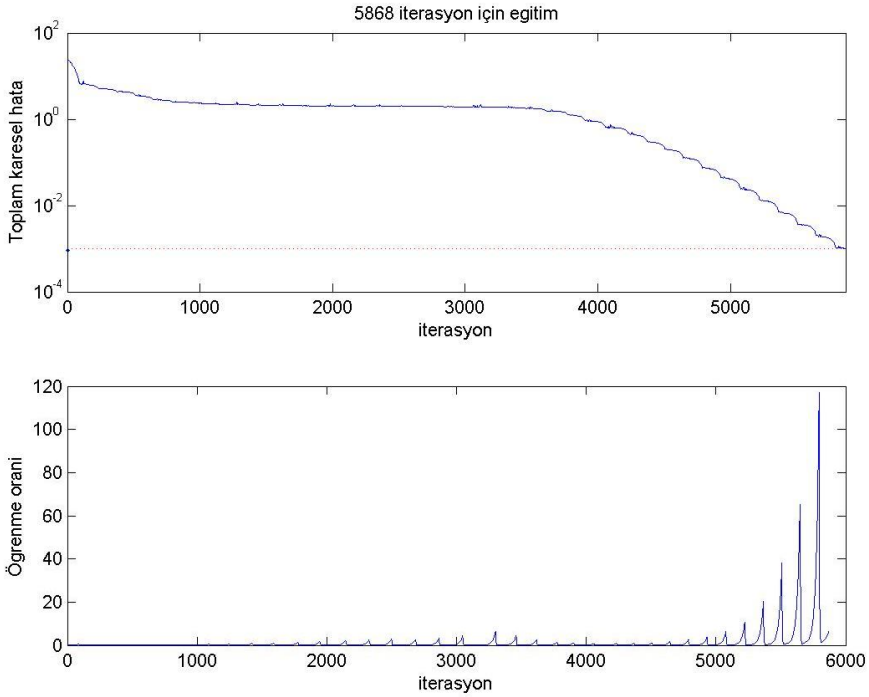

Şekil 5.10. YSA eğitim başarımı – II (Test veri seti ile YSA eğitilmiştir)

Dalgacık dönüşümü ve fraktal boyut hesaplaması ile DKS işaretinin özellik uzayının boyut olarak küçük olması sağlanarak, sınıflayıcının karmaşıklığını (YSA'da daha az nöron ve ara katman kullanılmasını sağlar) önlediği için tasarlanan sistemi gerçek zaman uygulamalarına daha uygun hale getirmekte ve tasarımını kolaylaştırmaktadır.

Kullanılan çok katmanlı hata geri yayınımlı YSA yapısı ile ilgili bilgiler Tablo 5.2'de verilmiştir. Başlangıç ağırlıkları ve eşik değerleri Matlab programında hazır fonksiyonları *(nwlog)* bulunan Nguyen-Widrow yöntemine göre hesaplanmıştır.

Tablo 5.2. Kullanılan YSA modelinin yapısı ve eğitim parametreleri

YSA yapısı	
YSA modeli	Çok katmanlı hata geri yayınım ağı
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 13 Gizli :15 Çıkış : 2
Başlangıç ağırlıkları ve eşik değerleri	Nguyen – Widrow metoduna göre hesaplandı
Etkinleştirme fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geri yayınım
Adaptif öğrenme oranı	Başlangıç : 0.01 Artış katsayısı : 1.05 Azalış katsayısı: 0.7
Momentum sabiti	0.95
Toplam karesel hata	0.0001

Sistemde eğitim (Veri Seti – 1: 15 normal, 25 anormal) ve test (Veri Seti – 2: 20 normal, 33 anormal) verileri mevcuttur. Önce eğitim verilerini kullanarak sonra da test verilerini kullanılarak sistem başarımı denenmiştir. Toplamda 93 veriden elde edilen veriler Tablo 5.3'e işlenmiştir. Ayrıca Tablo 5.3'te önerilen DKS işaretlerinin sınıflama sisteminin başarı durumları verilmiştir.

Tablo 5.3. DKS işaretlerinin sınıflandırma başarımı

Sınıflama Uygulamaları		YSA Test Sonuçları	
		Normal	Anormal
UYGLAMA I Veri seti – 2 ile YSA eğitilmiştir. Veri Seti - 1 ile YSA test edilmiştir.	DKS işaretleri	15	25
	Eğitim başarımı	%100	%100
	Doğru sınıflama	12	23
	Hatalı sınıflama	3	2
	En yüksek tanıma yüzdesi	%100	%100
	En düşük tanıma yüzdesi	%0.5	%0.3
	Başarım yüzdesi	%87.5	
UYGLAMA II Veri seti – 1 ile YSA eğitilmiştir. Veri Seti - 2 ile YSA test edilmiştir.	DKS işaretleri	20	33
	Eğitim başarımı	%100	%100
	Doğru sınıflama	15	29
	Hatalı sınıflama	5	4
	En yüksek tanıma yüzdesi	%99.86	%99.98
	En düşük tanıma yüzdesi	%0.6	%0.1
	Başarım yüzdesi	%83.01	
Ortalama başarım yüzdesi		%85.2	

6. SONUÇ VE DEĞERLENDİRME

Bu tez çalışmasında, durağan olmayan işaretlerin içermiş oldukları bilgi miktarının ölçülmesi için entropi yöntemine alternatif olarak fraktal boyut hesaplaması kullanılmıştır. Kaynak [7] çalışmasının bir bölümünde yapılan, doppler kalp ses işaretlerinin dalgacık dönüşüm bileşenlerinin entropileri hesaplanarak yapay sinir ağları ile sınıflandırılmasına alternatif olarak, bu tez çalışmasında aynı işaretler kullanılarak, entropi hesaplama yerine hurst exponent katsayısı ile fraktal boyut hesaplaması yapılmıştır.

Kaynak [7] yapılan entropi kullanılarak yapılan çalışmada, DKS işaretlerinin doğru sınıflandırılma başarımı %95 iken, bu tez çalışmasında fraktal boyut kullanılarak yapılan hesaplamada ise doğru sınıflama başarımı %85 olarak bulunmuştur.

Durağan olmayan işaretlerde entropi hesaplama tekniği ile işaretin düzensizlik yapısından içerdiği bilgi hesaplanmaktadır. Fraktal boyut hesaplaması ise, duğrağan olamayan işaretteki benzerliklerin oranını ölçerek işaretin içerdiği bilgi miktarını bulmaktadır. Bu çerçevede, entropi hesaplama tekniğinin fraktal boyut hesaplama tekniğine göre durağan olmayan işaretlerde bilgi ölçümü için daha güçlü ve güvenilir sonuçlar verdiği görülmüştür.

Durağan olmayan DKS işaretlerinin dalgacık dönüşüm bileşenlerinin, benzer içerikleri üzerine kurulmuş bilgi ölçümleri her zaman için doğru sonuçlar vermeyebilmektedir. Dolayısı ile bu tür işaretlerin düzensizlik üzerine kurulu karakteristik yapılarından ötürü düzensizlik miktarını ölçen entropi yöntemi, benzerlik oranını ölçen fraktal boyut hesaplamasına göre daha gerçekçi sonuçlar verdiği yapılan tez çalışması uygulamaları ile gösterilmiştir.

6.1.Öneriler

Yapılan tez çalışmasının geliştirilmesine yönelik aşağıdaki öneriler oluşturulmuştur:

- DKS işaretlerinin dalgacık dönüşüm ağacı işaretin anlamlı olarak ayrışabileceği en son bileşene kadar oluşturulmasına yerine, daha küçük bir ağaç yapısı oluşturularak fraktal boyut hesaplamaları yapılması,
- Hust exponent katsayısı kullanılarak yapılan fraktal boyut hesaplamasının başka türleri (kutu sayma esasına dayanan fraktal boyut hesaplama gibi) benzerlik oranı ile bilgi ölçümü için kullanılması.

KAYNAKLAR

[1] Vahaplar, A., İnceoğlu, M.M., 2001. Veri Madenciliği ve Elektronik Ticaret, Ege Üniversitesi Bilgisayar Müh. Böl., S. 2-6.

[2] Türkoğlu, İ., 2003. *Örüntü tanıma ders notları*, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

[3] Akgöbek, Ö., Çakır, F., 2009. Veri Madenciliğinde Uzman Sistem Tasarımı, Akademik Bilişim' 09 - XI. Akademik Bilişim Konferansı Bildirileri, Harran Üniversitesi, Şanlıurfa.

[4] Cambazoğlu,T. "Sayısal İşaret İşlemede Bir Dsp Mimarisinin İncelenmesi ve Uygulamaları", Elektrik Mühendisliği Dergisi 378. Sayı S.31-38.

[5] http://mennan.kagitkalem.com/default,month,2006-03.aspx Mennan On Writing 12 Mayıs 2009.

[6] http://www.bme.boun.edu.tr/bulten/kilavuz/enstrumantasyon.pdf Biyomedikal Klavuz Enstrümantasyon, Boğazici Üniversitesi Biyomedikal Mühendisliği Enstitüsü Bülteni, 12 Mayıs 2009.

[7] Türkoğlu, İ., 2002. *Durağan olmayan işaretler için zaman-frekans entropilerine dayalı akıllı örüntü tanıma*, *Doktora Tezi*, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

[8] Stein, J.Y., 2000. *Digital signal processing: a computer science perspective.* John Wiley & Sons, New York, 870s.

[9] Hopgood, J.R., 2000. Nonstationary signal processing with application to reverberation cancellation in acoustic environments, *Doktora Tezi*, Cambridge Üniversitesi, İngiltere.

[10] Cardoso, J.C.S., Ruano, M.G., Fish, P.J., 1996. *Nonstationarity broadening reduction in pulsed doppler spectrum measurements using time-frequency estimators,* IEEE Transaction Biomedical Engineering, 43, No.12, 1176 – 1186.104.

[11] Donoho, D.L., Johnston, I.M., 1994. *Ideal spatial ahnstonaptation via wavelet shrinkage, Biometrika*, Vol. 81, Pp-425-455.

[12] Matlab Wavelet Toolbox Dökümanları (Lisans No:585775)

[13] Mısıtı, M., Mıssıtı, Y., Oppenheım, G., Poggı, J.M., 1997-2002. *Wavalet toolbox for use width matlab*, user's guide, the mathworks inc.

[14] Alp, H., Akıncı, T.Ç., Albora, M., 2008. *Jeofizik uygulamalarda fourier ve dalgacık dönüşümlerinin karşılaştırılması,* Mühendislik Bilimleri Dergisi, 14 (1) 67-76 70.

[15] Aytaç, U., *www.mat.itu.edu.tr/unalmis*, 21 Şubat 2005.

[16] Dowla, U.F., Anat, S.K., 1997. *Wavelet transform methods for phase indentification in tree component seismograms*, Bulletin Of Seismological Society Of America, Vol, 87, No.6., Pp, 1598-1612.

[17] www.emclab.umr.edu/emap4/pml.html Perfectly Matched Layers. 13 Kasım 2005.

[18] Kil, D.H., Shin, F.B., 1996. *Pattern recognition and prediction with applications to signal characterization*, Aıp Press, USA, 417s.

[19] Fidan, S., 2006. Dalga kılavuzunda yayılan elektromanyetik dalganın dalgacık dönüşümü ile modellenmesi, *Yüksek Lisans Tezi,* Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

[20] Mintzer, F., 1985. *Filters for distortion-free twoband multirate filter banks*, IEEE Trans. Acoust., Speech And Singnal Proc 33(3): Pp.626-630.

[21] Nguyen, T., Strang, G., 1996. *Wavelets and filter banks*, Wellestey-Cambridge Press, Massachusettes, USA.

[22] Eroğul, O., Bahadırlar, Y., Güler, E.Ç. ve Aydın, H., 1999. Uyumlu Dalgacık Yöntemi Kullanılarak Uyku İğciklerinin Parametrik Çözümlemesi", BİYOMUT 99 Biyomedikal Mühendisliği Ulusal Toplantısı Bildiriler Kitabı, 200-206, Kayseri.

[23] www.sendika.org/yazi.php?yazi_no=27179# Marksizm ve modern bilim-3 Kaos teorisi, kelebek etkisi ve fraktallar. 24 Ekim 2009.

[24] www.tekplatform.com/matematiksel/577553-fraktal-geometri.html Fraktal Geometri-Teknolojinin Adresi & TEKplatform. 02 Haziran 2009.

[25] www.matematikce.net/mfraktallar.html Matematik Ufku. 23 Mayıs 2008.

[26] http://tr.wikipedia.org/wiki/Fraktal Fraktal – Vikipedi. 21 Haziran 2008.

[27] www.sinancanan.net/net/index.php?option=com_content&view=article&id=110:fraktallar&catid=41:bilimyorum&Itemid=71 Fraktal Geometri: Kaosun Resmi. 23 Mayıs 2008.

[28] Cantor, G., 1983. *Uber un-endliche, lineare punktmannigfaltigkeiten v*, Mathematische Annalen 21 545-591.

[29] www.xxanadu.org/fraktaller.htm Fraktaller ve Kaos. 23 Mayıs 2008.

[30] Barclay, A.L., Sweeney, P.J, Dissado, L.A. and Stevens, G.C., 1990. *Stochastic modelling of electrical treeing: fractal and statistical characteristics*, Journal of Physics d:Applied Physics 23 1536-1545.

[31] www.metu.edu.tr/~e128393/index.html Fraktallar. 23 Mayıs 2008.

[32] Falconer, K.J., 1990. *Fractal geometry: mathematical foundations and applications*, New York.

[33] www.matematikgeometri.com/altsayfalar/geomakaleler.html#FRAKTAL_GEOMETRİ_ Fraktal ve Fraktal Geometri. 12 Temmuz 2009.

[34] www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-97331998000200007 Brazilian Journal Of Physics- Fractals And Distribution Of Galaxies. 01 Mart 2008.

[35] Gürsakal N., http://homepage.uludag.edu.tr/gursakal/fraktal.html, 04 Aralık 2008.

[36] www.genbilim.com/content/view/417/90 Türkiye Bilim Sitesi. 23 Mayıs 2008.

[37] www.ercangurvit.com/fraktal.htm Fraktallar. 28 Mayıs 2008.

[38] http://ecademy.agnesscott.edu/~lriddle/ifs/carpet/carpet.htm Sierpinski Carpet. 14 Mart 2008.

[39] Öztürk, G., 1990. *Kaos: Düzensizliğin düzeni*, Bilim ve Teknik, syf 8, Sayı 273.

[40] Erzan, A., 1998. *Doğadaki fraktallar*, Bilim ve Teknik, syf 34, sayı 365.

[41] Ufuktepe, Ü., Aslan, İ., 2002. *Fraktal geometriden bir kesit*, Matematik Dünyası-C:11-s:1-Syf:14.

[42] Savacı, F.A., 2003. Fraktal Geometri ve Hoşgörü, http://www.iyte.edu.tr/~acarsavaci/Fraktal%20Geometri.doc, 23 Mayıs 2008.

[43] Gedik, İ., 1998. *Dünyanın oluşumundan insanlığın gelişimine: değişimler ve dönüşümler,* Karadeniz Teknik Üniversitesi, Jeoloji Mühendisliği Bölümü, Us-Jeoloji Müh., Sayı 52, Syf 75-139.

[44] britton.disted.camosun.bc.ca/jbnautilus.htm Chambered Nautilus. 11 Kasım 2009.

[45] sinancanan.net/2009/02/13/mss-2/ İnsan Sinir Sistemi-2. 11 Kasım 2009.

[46] www.harunyahya.org/bilim/kan_kalp/kanvekalp12.html Kan ve Kalp Mucizesi. 11 Kasım 2009.

[47] www.matematikkulubu.org/modules.php?name=News&file=article&sid=510 Fraktallar. 04 Haziran 2008.

[48] goto.bilkent.edu.tr/gunce/forum_posts.asp?TID=948 Aradakileri Keşfetmek. 04 Haziran 2008.

[49] Ufuktepe, Ü., Aslan, İ., 2002. *Fraktal geometriden bir kesit*, Matematik Dünyası-C:11-s:1-Syf:15

[50] tr.wikipedia.org/wiki/Fraktal Fraktal. 23 Mayıs 2008.

[51] www.metu.edu.tr/~e128393/son10.html Fraktalların Kullanım Alanları. 23 Mayıs 2008.

[52] ti.arc.nasa.gov/publications/pdf/iafa.pdf İntelligent Systems Division. 23 Mayıs 2008.

[53] www.matematikkulubu.org/modules.php?name=News&file=article&sid=510 Matematik Klubü. 23 Mayıs 2008.

[54] www.musl.org/images/fractal_hand.jpg musl.org. 13 Kasım 2007.

[55] D. R. Morse, J. H. Lawton, M. M. Dodson, M. H. Williamson, 1985. *Fractal dimension of vegetation and the distribution of arthropod body lengths*, Nature 314, 731 – 733.

[56] myweb.lmu.edu/pharris/WTmed%20liftoff%20towers.jpg Paul A. Harris Home. 05 Mayıs 2008.

[57] www.kavramsitesi.org/dokuman_ara.asp?cmbKategori=0&txtKelime=kaos Doğanın Kesirli Geometrisi. 13 Haziran 2008.

[58] www.kavramsitesi.org/admin/uploads/%7B4961ACFC-14CF-4A96-90C8-FB255F9181FE%7D.pdf Doğanın Kesirli Geometrisi. 13 Haziran 2008.

[59] Koçak, Ş., 2004. *Fraktaller*, Matematik Dünyası, Bahar, Syf: 66-67.

[60] www.people.umass.edu/partee/409/Appendix%20non-Euclidean.pdf Barbara Partee. 23 Mayıs 2008.

[61] http://www.marksist.com/book/export/html/617 Aklın İsyanı. 26 Mayıs 2008.

[62] odevlerimburda2008.blogcu.com/fraktal-nedir_5277621.html Fraktal nedir? 24 Mayıs 2008.

[63] Jelinek, F., Cameron, L.J., Matthew, D.W., Cecile, L., Cecile, D., Gaelle, A., 2006. *Understanding fractal analysis? The case of fractal linguistics*, Complexus 3:66-73.

[64] Sevcik, 2005. *Linear correlation between fractal dimension of EEG signal and handgrip force,* Volume 93 Number 2, page 131-140.

[65] Gürsakal, N., 1999. *Lojistik Denklemden Türetilen Verilerin Fraktal Boyut Tahminleri*, IV. Ulusal EkonometTİ ve İstatistik Sempozyumu Bildirileri.

[66] Ürey, H., 2006. Fraktal geometri ve uygulamaları, Yüksek Lisans Tezi, Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Afyon.

[67] Mandelbrot, B.,Wheeler, J.A., 1983. *The fractal geometry of nature*, American Journal of Physics, s1(3), 286-287.

[68] Olemskoi and Flat,1983. *Application of fractals in condensed-matter physics*, PHYS-USP, 36(12), 1087-1128.

[69] www.yapay-zeka.org/modules/wiwimod/index.php?page=ANN Yapay zeka org –ansiklopedi - yapay sinir ağları(artificial Neural Networks) 10 Eylül 2009.

[70] www.nostaljim.org/B3/viewtopic.php?f=15&t=3287 Nostaljim.org - Epilepsi Nedir? 10 Eylül 2009.

[71] Sağıroğlu Ş., Beşdok E., Erler M., 2003. Mühendislikte Yapay Zeka Uygulamaları-1/Yapay Sinir Ağları, Ufuk Kitap Kırtasiye Yayıncılık Ltd. Şti., Kayseri.

[72] Türker, N. ve Güneş, F., 2004, "Mikroşerit Dalga Kılavuzu Transmisyonu için Yapay Sinir Ağı Modeli Geliştirilmesi", Akıllı Sistemlerde Yenilikler Ve Uygulamaları Sempozyumu İstanbul-Türkiye.

[73] Batar, H., 2005, "EEG işaretlerinin dalgacık analiz yöntemleri kullanılarak yapay sinir ağları ile sınıflandırılması", Sütçü İmam Üniversitesi, Yüksek Lisans Tezi, Kahramanmaraş.

[74] Akgündoğdu, A., 2003. Bulanık yapay sinir ağları ile görüntü işlenmesi, *Yüksek Lisans Tezi,* İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

[75] Rumelhart, D.E., Macclelland, J.L., 1986. *Parallel distributed processing: Explorations in the microstructure of cognition*, Vol. I, Mıt Press, Cambridge, Ma.

[76] Bilgin, S., 2008. Kalp hızı değişkenliğinin dalgacık dönüşümü ve yapay sinir ağları kullanılarak analizi, *Doktora Tezi*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.

[77] Rosenblatt, F., 1958. *The perceptron: A probabilistic model for ınformation storage and organization in the brain,* Psychological Review, Vol. 65, Pp. 386–408.

[78] Hu, Y.H., Hwang, J.N., 2002. *Handbook of neural network signal processing*, Crc Pres, Washington D.C.

[79] Gupta, M.G., Jın, L., Homma, N., 2003. *Static and dynamic neural networks: from fundamentals to advanced theory*, IEEE Pres, Wiley Interscience, Usa.

[80] Öztemel E. 2003. Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.

[81] Fauset L. 1994. Fundamentals of neural networks: Architectures, Algorithms and Applications. Prentice Hall, Inc. A Simon&Schuster Company.

[82] Haykin S. 1994. Neural Networks: A Comprehensive Foundation. New York:Macmillan.

[83] Mitchell T.M. 1997. Machine Learning. The McGraw-Hill Companies, Inc. Portland.

[84] Tezel, G., 2007. Biyomedikal işaretlerin yeni bir adaptif aktivasyon fonksiyonlu yapay sinir ağı ile sınıflandırılması, *Doktora Tezi,* Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

[85] Acır, N., 1998. Yapay nöral ağ temelli meteorolojik parametrelerin tahmini, *Yüksek Lisans Tezi*, Niğde Üniversitesi Fen Bilimleri Enstitüsü, Niğde.

[86] Toprak, İ., B., 2007. Eeg sinyallerinin dalgacık dönüşümü ve yapay sinir ağları ile analizi, *Yüksek Lisans Tezi*, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta.

[87] Übeyli, E.D., Güler, İ., 2003. *Neural network analysis of internal carotid arterial doppler signals: predictions of stenosis and occlusion*, Expert Systems With Applications, 25(1), 1-13.

[88] Kordylewski, H., Graupe, D., Liu, K., 2001. A *novel large-memory neural network as an aid in medical diagnosis applications*, IEEE Transactions On Information Technology İn Biomedicine, 5(3), 202-209.

[89] www.tkv.org.tr/index.php?sa%f0l%fdk_servisleri/renkli_doppler_ve_ultrasonografi, Türk Kalp Vakfı – Renkli Doppler ve Ultrasonografi. 12 Temmuz 2009.

[90] www.bebekbeklerken.com/detay.asp?id=35 Renkli doppler ultrasonografi ve fetal ekokardiografi - Bebek Beklerken… 12 Temmuz 2009.

[91] http://320volt.com/sayisal-isaret-islemeye-giris-dsp-hakkinda, Sayısal İşaret İşlemeye Giriş DSP hakkında Elektronik devreler projeler. 12 Temmuz 2009.

[92] Kayran, A.H., Ekşioğlu, E.M., 2004. Bilgisayar Uygulamalarıyla Sayısal İşaret İşleme, Birsen Yayınevi, İstanbul.

[93] Schlichthatle, D., 2000. Digital Filters Basics and Design, Springer, 361 pp. Germany.

[94] Ertürk, S., 2004. Sayısal İşaret İşleme, Birsen Yayınevi, İstanbul.

[95] Özgün, A., Önder, M., www.muhteva.com/digital-filtreler-t21448.html Digital Filitreler, 15 Mart 2008.

[96] www.bilgiagaci.com/index.php?option=com_content&task=view&id=64 Bilgi Agacı - İleri Beslemeli Yapay Sinir Ağlarında Backpropagation(Geri Yayılım) Algoritması. 19 Temmuz 2009.

ÖZGEÇMİŞ

1983 yılında Elazığ'da doğdu. İlkokulu Vali Tevfik Gür İlköğretim Okulunda, orta okulu Balakgazi Lisesi'nde okudu ve aynı okulda süper lise hazırlık sınıfında 1 yıl eğitim aldıktan sonra, lise öğrenimini Özel Harput Lisesi'nde 2001 yılında tamamladı. Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik Bilgisayar Bölümü Bilgisayar Öğretmenliğini 2001 yılında kazanarak, 4 yıl süren eğitimin ardından Kayseri Pınarbaşı İlçesi Çok Programlı Lisesi'nde Bilgisayar Öğretmeni olarak göreve başladı. 2007 Şubat döneminde Fırat Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Sistemleri alanında yüksek lisansa başladı. 2007 yılında İlçe Milli Eğitim Müdürlüğü'nde Eğitici formatör olarak göreve başladıktan 1 ay sonra Kayseri Valiliği onayı ile Şube Müdürlüğü görevine getirildi ve halen Pınarbaşı İlçe Milli Eğitim Müdürlüğü'nde Vekaleten Şube Müdürlüğü görevini sürdürmektedir.