

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**DALGACIK AĞLARIYLA ELEKTROKARDİYOGRAFİK ARİTMİLERİN
SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ
Abdullah KARADAĞ**

Anabilim Dalı : Elektronik ve Haberleşme Mühendisliği

Programı : Biyomedikal Mühendisliği

Tez Danışmanı: Doç. Dr. Mehmet KORÜREK

HAZİRAN 2009

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**DALGACIK AĞLARIYLA ELEKTROKARDİYOGRAFİK ARİTMİLERİN
SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ
Abdullah KARADAĞ
(504021412)**

Tezin Enstitüye Verildiği Tarih : 04 Mayıs 2009

Tezin Savunulduğu Tarih : 03 Haziran 2009

Tez Danışmanı : Doç. Dr. Mehmet KORÜREK (İTÜ)

Jüri Üyeleri : Prof. Dr. Tayfun AKGÜL(İTÜ)

Yrd. Doç. Dr. Mustafa E. KAMAŞAK (İTÜ)

HAZİRAN 2009

ÖNSÖZ

“Dalgacık Ağlarıyla Elektrokardiyografik Aritmilerin Sınıflandırılması” isimli yüksek lisans tez çalışmamı tamamlamış durumdayım. Tez çalışmam boyunca emek ve fikirlerinden istifade ettiğim değerli hocalarıma, arkadaşlarıma ve aileme en içten şükran duygularımı sunmayı bir borç bilirim.

Tez çalışmamda büyük emeği bulunan, sabırla beni dinleyip her türlü sorunumu çözmekte bana büyük bir özveri ile yardımcı olan, engin tecrübesiyle bilimsel düşünce ufkumu genişleten Sn. Doç. Dr. Mehmet KORÜREK'e; benden evvel henüz bu aşamadan geçmiş bulunmaları hasebiyle tecrübelelerinden istifade ettiğim araştırma görevlisi arkadaşlarıma teşekkür etmeyi bir borç bilirim.

Kaybetmek üzere olduğum yüksek lisans hakkımı tekrar aramamda bana engin tecrübesiyle yol gösteren eski yöneticim Sn. Ömer YILDIZ'a ve çok değerli avukat arkadaşşıma özellikle teşekkürlerimi sunmayı bir borç bilirim.

Hayatım boyunca bana her konuda destek olarak bugünlere gelmemde en büyük vesile olan ve sıkıntılı günlerimde her an desteğini hissettiğim aileme sonsuz teşekkür ve minnet duygularımı sunmaktan onur duyarım.

Yaptığım çalışmanın güzel ülkeme ve tüm insanlığa hayırlı olmasını dilerim.

Saygılarımla...

Haziran 2009

Abdullah KARADAĞ

Elektronik ve Haberleşme Müh.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ.....	iii
İÇİNDEKİLER.....	v
KISALTMALAR.....	vii
ŞEKİL LİSTESİ.....	ix
ÖZET.....	xiii
SUMMARY.....	xv
1. GİRİŞ	1
1.1 Amaç.....	1
1.2 Literatür Özeti	2
1.3 Kapsam	2
2. ELEKTROKARDİYOĞRAFI VE ARİTMİLER.....	5
2.1 Kalbin Fizyolojisi	5
2.2 EKG İşareti	6
2.2.1 Tanım.....	6
2.2.2 EKG işaretinin bileşenleri.....	6
2.3 Aritmiler.....	8
3. DALGACIK ANALİZİ.....	15
3.1 Dalgacık Temelleri	15
3.2 Dalgacık Dönüşümü	16
3.2.1 Morlet dalgacık fonksiyonu	17
3.2.2 Meksika Şapkası dalgacık fonksiyonu	18
4. YAPAY SİNİR AĞLARI.....	19
4.1 Yapay Sinir Ağının Tanımı.....	19
4.2 Çok Katmanlı Almaç Ağı (ÇKA, “Multi-layer Perceptron”)	21
4.2.1 Geriye yayılım (“back-propagation”) algoritması.....	22
4.3 İstatistiksel Sinir Ağları	22
4.3.1 Radyal tabanlı fonksiyon ağları.....	24
4.3.2 Genel doğrusal öngörü sinir ağları	26
4.3.3 İstatistiksel sinir ağları.....	27
5. DALGACIK AĞLARI (WAVENET) VE UYGULAMALARI.....	29
5.1 Tanım.....	29
5.2 Geliştirilen Uygulamanın Yapısı.....	29
5.2.1 Adaptif istatistik dalgacık ağı (AİDA)	29
6. GERÇEKLEŞTİRİLEN YÖNTEMİN UYGULAMASI.....	33
6.1 Önışlemler	33
6.1.1 İşarete uygulanacak dikdörtgen pencerenin belirlenmesi	34
6.1.2 Genlik ayarı.....	35
6.1.3 Median ile taban hattı düzeltmesi.....	35
6.1.4 Önışlemler için geliştirilen MATLAB uygulaması.....	37
6.2 RR Aralığının Belirlenmesi	38
6.3 Sınıflayıcı Olarak Dalgacık Ağı.....	39

6.4 Sınıflayıcı Olarak Çok Katmanlı Ağ	39
6.5 Uygulamanın Giriş Verisi ve MIT-BIH Veritabanı	40
7. SONUÇLAR VE DEĞERLENDİRME.....	43
KAYNAKLAR.....	53

KISALTMALAR

AİDA	: Adaptif İstatistik Dalgacık Ağı
APC	: Erken Kulakçık Kasılması (Premature Atrial Contraction)
ÇKA	: Çok Katmanlı Almaç
EKG	: Elektrokardiyogram
ECG	: Electrocardiogram
GRNN	: Genel Doğrusal Öngörü Sinir Ağı (General Regression Neural Network)
GY	: Geriye Yayılım
İDA	: İstatistiksel Dalgacık Ağı
PNN	: İstatistiksel Yapay Sinir Ağı (Probabilistic Neural Network)
PVC	: Erken Karıncık Kasılması (Premature Ventricular Contraction)
RBBB	: Sağ Dal Blok (Right Bundle Branch Block)
RR	: EKG'de peşpeşe iki R dalgası arası süre
RBF	: Radyal Tabanlı Fonksiyon Ağı (Radial Basis Function Network)
SA	: Sino-Atrial Düğüm (Sinus Atrium)
YSA	: Yapay Sinir Ağı

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Kalbin temel yapısı.	6
Şekil 2.2 : EKG işareti süre.....	7
Şekil 2.3 : Kalpte uyarı iletim yolları.	7
Şekil 2.4 : Çeşitli aritmilerde kalp ritmindeki değişim.....	9
Şekil 3.1 : Morlet Dalgacıđı	15
Şekil 3.2 : Ötelenmiş ve ölçeklenmiş Morlet dalgacıđı.....	16
Şekil 3.3 : Meksika Şapkası dalgacıđı.	18
Şekil 4.1 : YSA İşlem elemanının yapısı	20
Şekil 4.2 : YSA'nın genel yapısı.....	21
Şekil 4.3 : K- En yakın komşu ağlarında iki boyutlu bir noktanın arzulanan çıkış değerinin bulunması	23
Şekil 4.4 : Gauss fonksiyonunun çıkışı (sigma = 1).....	25
Şekil 4.5 : Gauss fonksiyonunun çıkışı (sigma = 0.2).....	26
Şekil 5.1 : Adaptif istatistik dalgacık ađı.....	30
Şekil 6.1 : Sistemin blok diyagramı	33
Şekil 6.2 : Önışlemlerden geçmemiş ardışık iki Normal EKG vurusu	34
Şekil 6.3 : İşarete uygulanan zaman penceresi	34
Şekil 6.4 : N vurusunun sınıf içi saçılımı (Normalizasyon yok).....	36
Şekil 6.5 : N vurusunun sınıf içi saçılımı (Normalizasyon var).....	36
Şekil 6.6 : V vurusunun sınıf içi saçılımı (Normalizasyon yok).....	37
Şekil 6.7 : V vurusunun sınıf içi saçılımı (Normalizasyon var).....	37
Şekil 6.8 : Elektrokardiyogram işaretinin güç spektrumu (360 Hz ile örneklenmiş).41	
Şekil 7.1 : İstatistiksel Dalgacık Ağında giriş vektörü boyutu - ağ başarıım oranı değişimi	45
Şekil 7.2 : Dalgacık ađı çalışma süresi (eđitim+test) süresinin giriş vektörü boyutuna göre deđişimi	46
Şekil 7.3 : Çok Katmanlı Ağda giriş vektör boyutu - ağ başarıım oranı deđişimi ...	47

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 7.1 : Median filtrenin başarıma etkisi.	44
Çizelge 7.2 : Genlik ayarının başarıma etkisi ...	47
Çizelge 7.3 : İndirgenmiş giriş vektörü ile ağ başarımları ...	48
Çizelge 7.4 : RR oranın ağ başarımlarına olan katkısı ...	49
Çizelge 7.5 : Eğitim kümesindeki vektör sayısının başarıma ve çalışma süresi üzerindeki etkisi	49
Çizelge 7.6 : Dalgacık Ağı ortalama sınıflama başarıma matrisi....	50
Çizelge 7.7 : YSA ortalama sınıflama başarıma matrisi. ...	51
Çizelge 7.8 : Normal sınıfı için ortalama duyarlılık ve belirlilik oranları ...	51

DALGACIK AĞLARIYLA ELEKTROKARDİYOĞRAFİK ARİTMİLERİN SINIFLANDIRILMASI

ÖZET

Elektrokardiyogram kayıtları kalple ilgili hastalıkların teşhisinde önemli bir yer tutmaktadır. Normal bir insanda düzenli bir periyodu ve şekli olan elektrokardiyogram hastalık durumunda hem şekil olarak hem de tekrarlama sıklığı olarak değişime uğrayabilmektedir. Bu değişikliklerin ne anlama geldiğini anlayabilmek ve anlamlı bir şekilde sınıflandırmak için kayıtlar üzerinde detaylı ve uzun incelemeler yapmak gereklidir. Teşhislerin bilgisayar destekli olarak yapılabilmesi geçmiş verilerin kaydı ve yeni verilerin kıyası ile mümkün olmakta ve bu da sisteme depolama alanı ve işlemci hızı bakımından yüksek bir külfet getirebilmektedir. Bu maliyeti düşürebilmek için geliştirilmiş çok sayıda uzman sistemler mevcuttur. Bilinen uzman sistemlerin çoğu yapay sinir ağlarını kullanmaktadır. Son zamanlarda bu sistemlerin belirli katmanlarında yaygın olarak dalgacık dönüşümleri kullanılmaya başlanmıştır.

Bu çalışmada, kaskad bağlanmış bir dalgacık katmanı ve bir istatistiksel yapay sinir ağından (Probabilistik neural network, PNN) oluşan dalgacık ağının (Wavenet) Elektrokardiyogram vurularını sınıflamadaki başarımı, çok bilinen bir sınıflayıcı olan Çok Katmanlı Yapay Sinir Ağı (ÇKA, ing. Multi-Layer perceptron, MLP) ile kıyaslanarak ortaya konmaya çalışılmıştır. Ayrıca sistemin başarımını artırmak amacıyla giriş parametreleri üzerinde araştırmalar yapılmış ve hem boyut olarak hem de etkinlik olarak giriş parametreleri eniyileştirilmeye çalışılmıştır. Elde edilen giriş parametreleri her iki ağa uygulanarak, kullanılan algoritmadan bağımsız etkileri üzerinde durulmuştur. Bunların yanı sıra uygulanan farklı ön işlemlerin de sonuca olan katkıları grafiklerle ortaya konmuştur.

Klasik yapay sinir ağları metotlarında sınıflayıcıya sokulacak giriş vektörleri önceden öznitelik çıkarma olarak bilinen bir evreden geçmektedir. Bu evrede öznitelik adı verilen işaretin ayırt edici parametreleri gelişmiş algoritmalar kullanılarak belirlenmektedir. Dalgacık ağlarının ilk katmanı olan dalgacık katmanı bu özniteliklerin dinamik bir şekilde elde edilmesini sağlamaktadır. Birçok klasik bölütleme algoritmasında frekans domeninden alınan özniteliklerin yanı sıra zaman domeninden öznitelikler de -EKG'nin doğası gereği- başarımı artırmak için kullanılır. Dalgacık ağları, dalgacıkların bir işareti hem frekans domeninde hem de zaman domeninde çok iyi bir çözünürlükle temsil edebilmeleri yetenekleri sayesinde, doğal olarak hem zaman domeninden hem de frekans domeninden öznitelikleri bünyelerinde barındırırlar.

İstatistiksel yapay sinir ağı katmanında, dalgacık ağları kısmında elde edilen öznitelik vektörleri kullanılarak sınıflama yapılır. Dalgacık ağları gerçek dünyaya uygulandığında, mesela EKG işaretleri farklı hastalar için farklı morfolojilere sahip olabilmekte ve hatta bazı durumlarda aynı hastalar için bile değişik morfolojideki işaretler elde edilebilmektedir, klasik ağlar için bir şişe boynu sorunu ortaya çıkmakta ve veritabanına yeni öznitelikler alınarak ağın yeniden eğitilmesi gerekmektedir. PNN (İstatistiksel Yapay Sinir Ağı, “Probabilistic Neural Network”) ve GRNN (Genel Doğrusal Öngörü Sinir Ağları, “General Regression Neural Network”) gösterilmiştir ki, ve görülmektedir ki, bu durumlarda çok esnek ve giderek iyileşen ağ yapısına, yüksek öğrenme hızına ve umut veren sonuçlara haizdir (Lin ve diğ., 2008).

Çalışma için kullanılan EKG işaretleri MIT-BIH veritabanı kanal II’den alınmıştır. İşaretler 360 Hz ile örneklenmiş, 11-bit çözünürlükte olup 10mV’luk bir aralığı temsil edebilmektedir. Sınıflanacak veriler farklı iki hasta grubundan alınmak suretiyle hastanın yaşı, cinsiyeti vs. özel durumlarının sonuca olan etkisi en aza indirilmiştir. Tez boyunca yapılan ayrıntılı testler genelde birinci hasta grubu üzerinden yapılmıştır. Bu hastalar MIT-BIH veri tabanındaki 106, 109, 209 ve 212 nolu hastalardır. Gupta Normal vurusu (N) bulunan üç hastadan yedişer vektör alınarak toplam 21 Normal vektörü oluşturulmuştur. Diğer hastalardan barındırdıkları aritmi tipinden 21 vektör seçilmiştir. Diğer aritmi tipleri; erken karıncık kasılması (V), erken kulakçık atımı (A), sol dal blok vurusu (L) ve sağ dal blok vurusudur (R). Birinci hasta grubuyla karşılaştırmak maksadıyla tamamen farklı hastalardan oluşturulan ikinci hasta grubu da 103, 119, 124, 200, 214 ve 232 nolu hastalardır. Bu hastalardan aritmiler alınırken yine birinci grubun seçiminde kullanılan mantık kullanılmış ve Normal vurusunun (N) yanı sıra belli bir aritmiyi barındıran hastalardan eşit sayılarda vektörler alınmıştır. N vurusu üç farklı hastadan, V vurusu iki farklı hastadan ve A vurusu da yine iki farklı hastadan alınmıştır. Bu farklılığı formüle edebilmek için vektör sayısı hem ikiye hem üçe bölünen 24 sayısına çıkarılmıştır. Test kümesinde her vurudan 120’şer tane alınmak suretiyle toplam 600 veri üzerinde sonuçlar incelenmiştir.

Dalgacık ağlarında tipik olarak işaretin kendisi ağın girişine uygulanır. EKG vurularında R tepesini merkez alıp QRS bölgesini içerisine alan dikdörtgensel bir pencere vurunun tipi hakkında hemen hemen tüm bilgiyi barındırır. Ancak bazı aritmi türlerinde QRS’in şeklinin yanı sıra RR aralığı da önemli bir anlam taşır. Bu amaçla *incelenen çalışmalarda bulunmayan ancak sınıflama başarımını artıracak düşüncesiyle RR aralığı da dalgacık ağına giriş olarak verilmiş ve verilmediği duruma göre ortalama sınıflama başarı oranını %18 artırdığı görülmüştür.* Bu katkı, çalışmamızın önemini ortaya koymaktadır.

ELECTROCARDIOGRAM ARRHYTHMIAS CLASSIFICATION USING WAVELET NETWORKS

SUMMARY

The Electrocardiogram (ECG) records play an important role in diagnosis of cardiac disease. The ECG signal is regular in shape and has a frequency between 60 and 100/min in a normal rhythm. But in case of a cardiac abnormality its shape or frequency is modified. In order to classify those abnormalities accurately there should be carried out detailed and long term analysis. A computer aided system needs to store past records and compare new data to them which requires a huge amount of storage and very fast processors. To reduce the storage and the processor cost various expert systems have been defined. Most of those systems are either completely or partially based on artificial neural networks. Nowadays there are introduced some systems which uses Wavelets in at least one layer of their network structure.

In this thesis, a cascaded network of wavelets and PNN (Probabilistic Neural Network) is applied as ECG heart beat classifier and is compared to one of the well-known ANN classifiers Multi-layer Perceptron. Moreover, in order to determine the effect of the input vector over the classification performance of both networks, different input vectors in different dimensions have been applied.

The feature extraction phase of traditional neural networks is carried out dynamically at run time by the wavelet layer part which is constructed from translated and dilated versions of the mother wavelet. In most of the feature extraction based neural network models, some features need to be selected from the time domain parameters because of the nature of the ECG heart beat signal. Wavelet transforms have the best resolution to represent a signal both in time domain and in frequency domain at the same time. Thus, they naturally include these two important features.

A good classification of heart beat input vectors is done at the probabilistic neural network part with the features extracted at the wavelet part. When WN is applied in the real world, for example, the morphology variations of ECG waveforms are different for different patients, and even for the same patient or for the same type, traditional networks can become a bottleneck requiring retraining with new features added into the current database. PNN and General Regression Neural Networks (GRNN) have been presented, and are recognized as having expandable or reducible network structure, fast learning speed, and promising results(Lin ve diğ., 2008).

The data used at this application is taken from the MIT-BIH heart beat database channel II. The signals are sampled at 360 Hz with 11-bit resolution over a 10 mV range. In order to avoid effects of subjects' age, sex and physiology two groups constituted of different subjects. In Group 1 there are four subjects from the MIT-BIH database with numbers 106, 109, 209, 212. This group's data is used in most of the tests. There are 21 Normal (N) beats (7 samples per subject), 21 premature ventricular contraction beats (V), 21 atrial premature beats (A), 21 left bundle

branch block beats (L) and 21 right bundle branch block beats (R) at the training set. The beat per class is 120 at the test set. In Group 2 there are six subjects from the MIT-BIH database with numbers 103, 119, 124, 200, 214 and 232. There are 24 Normal (N) beats (8 samples per subject), 24 premature ventricular contraction (V) beats (8 samples per subject), 24 atrial premature (A) beats (12 samples per subject), 24 left bundle branch block beats (L) and 24 right bundle branch block beats (R) at the training set. The beat per class is 120 at the test set.

In a typical wavelet network, the ECG signal itself is directly applied to the input of the network. A rectangular time window centered at R peak contains most of information required to classify an ECG beat. However, there are some arrhythmias that differ from others by not only the QRS shape but also the interval between two consecutive R peaks (RR interval). Thus, the RR interval parameter is added to the input vectors, to improve the classification performance. The %18 improvement in classification performance is achieved by applying the RR interval parameter. This improvement is the main contribution of this work.

1. GİRİŞ

1.1 Amaç

Elektrokardiyogram (EKG işareti) kalp hastalıklarının teşhisinde en çok kullanılan yöntemlerden biridir. EKG işaretlerinde ortaya çıkan ritim ve şekil bozuklukları (aritmiler) kalp hastalıkları hakkında önemli bilgiler vermektedir. Aritmilerin bilgisayar ortamında analiz edilmesi ve sınıflanması son yıllarda birçok araştırmaya konu olmuştur. EKG işareti üzerinden yapay sinir ağları, genetik algoritma, dalgacık dönüşümü ve sezgisel metotlara dayalı birçok uygulamalar geliştirilmiştir.

Bu konudaki en önemli zorluklardan biri EKG dalga şeklindeki değişkenliktir. EKG işaretleri farklı hastalar için farklı morfolojilere sahip olabilmekte ve hatta bazı durumlarda aynı hastalar için bile değişik morfolojideki işaretler elde edilebilmektedir. Bu durumda, klasik ağlar için bir şişe boynu sorunu ortaya çıkmakta ve veritabanına yeni öznitelikler alınarak ağın yeniden eğitilmesi gerekmektedir (Lin ve diğ., 2008).

Değişkenlik gösteren EKG işaretleri makul bir genelleme ile sınıflanabilirse hastalık teşhisine oldukça büyük katkı sağlar. Ayrıca birkaç saat süren uzun kayıtlar üzerinde analizler yapmaktansa işaretlerin sadece anlamlı kısımları üzerinde çalışmak işaretlerin hızlı bir şekilde yorumlanabilmesini sağlamaktadır. Çalışmanın amacı hızlı ve doğru bir sınıflama potansiyeline sahip İstatistiksel Dalgacık Ağının performansını literatürde oldukça iyi bilinen bir sınıflayıcı olan Çok Katmanlı Ağın performansı ile karşılaştırmak suretiyle ortaya çıkarmak ve giriş vektörlerini olabilecek en küçük boyutta ve en etkin parametrelerden seçerek sınıflama başarımını arttırmaktır.

1.2 Literatür Özeti

Dalgacık ağırları metodları literatürde sayısız uygulamalarda kullanılan oldukça etkili metotlardır. Özellikle veri sıkıştırma ve sistem modellemedeki yüksek başarıları başka alanlarda kullanımlarına öncülük etmiştir. Postalciöđlu ve diđ. (1997) alıřmalarında sistem modellemede dalgacık ağırları ve yapay sinir ağırlarını karřılařtırmıřlardır.

Yapay sinir ağırlarına göre oldukça hızlı bir řekilde sonuca yakınsayabilmeleri, iřlem karmařıklıđını dūřürüp alıřma hızını dūřürmeleri dalgacık ağırlarının birok uygulama alanında denenmesine yol amıřtır. Lecutai (1997) doktora tezinde dalgacık ağırları ile sūre kontrol alanında bařarılı alıřmalar yapmıřtır. Lin (1997) de lineer olmayan sistemlerin kontrolünde dalgacık ağırlarından istifade eden alıřmalar yapmıřtır.

Zang ve Benveniste (1992), dalgacık ağırlarının temellerini attıkları alıřmada böyle bir sistemin nasıl eđitileceđini ve bařarımının artırımı iin nelerin gerekli olduđunu kaleme almıřlardır.

Zang ve Xie (2006) oldukça farklı bir alanda; kısa sūreli trafik tahminleri alanında bu ağırları oldukça bařarılı bir řekilde uygulamıřlardır.

EKG vurularının sınıflamasında dalgacık ağırları henüz yaygın olmayan bir uygulamadır. Bu konudaki nadir alıřmalardan birisi Lin ve diđ. (2008)'in alıřmasıdır.

1.3 Kapsam

Tez ierisinde EKG iřaretlerindeki aritmi adı verilen řekil ve ritim bozukluklarının tespitinde İstatistiksel Dalgacık Ağırlarının (PNN) kullanımı anlatılmıřtır. Ayrıca aynı EKG verileri ok Katmanlı Alma (MLP, YSA, NN) ile sınıflandırılarak her iki yöntem tablolarla karřılařtırılmıřtır.

İkinci bölümde EKG iřaretleri ve aritmiler ile ilgili temel kavramlar hakkında kısaca bilgi verilmektedir. Tez kapsamında kullanılan aritmilerin yapısı hakkında ise detaylı bilgi verilmektedir.

Üçüncü bölümün başında Yapay Sinir Ağları (NN) ile ilgili temel bilgiler verilmiştir. Daha sonra kıyaslama için kullanılacak Çok Katmanlı Almaç ve İstatistiksel Dalgacık Ağında sınıflama katmanını oluşturan İstatistiksel Yapay Sinir Ağları (“Probabilistic Neural Network”, PNN) ayrıntılı olarak ele alınmıştır.

Dördüncü bölümde literatürde Dalgacık adı verilen fonksiyonlardan ve genel anlamda dalgacık analizinden bahsedilmiş ve tez çalışmasında kullanılan Morlet Dalgacığı ve Meksika Şapkası Dalgacığı’ndan özel olarak bahsedilmiştir.

Beşinci bölümde geliştirilen uygulamanın İstatistiksel Dalgacık Ağlarının yapısı ve çalışma prensipleri anlatılmıştır.

Altıncı bölümde sınıflama başarımını artırıcı ön işlemler ve filtrelerden bahsedilmiş ve verilerin alındığı MIT-BIH veri tabanı hakkında gerekli bilgiler verilmiştir.

Sonuç bölümünde kullanılan sınıflama yöntemlerinin başarımı tablolar halinde ortaya konmuştur. Ağa uygulanacak giriş parametreleri değiştirildiğinde elde edilen sonuçlar da kıyaslamalı olarak yine tablolar halinde verilmiştir.

Bu çalışmamızda, incelenen çalışmalarda bulunmayan ancak sınıflama başarımını artıracak düşüncesiyle RR aralığı Dalgacık Ağına ve ÇKA’ya ilave giriş olarak verilmiş ve verilmediği duruma göre ortalama sınıflama başarı oranını Dalgacık Ağlarında %18, ÇKA’da %9 artırdığı görülmüştür. Bu katkı, çalışmamızın önemini ortaya koymaktadır.

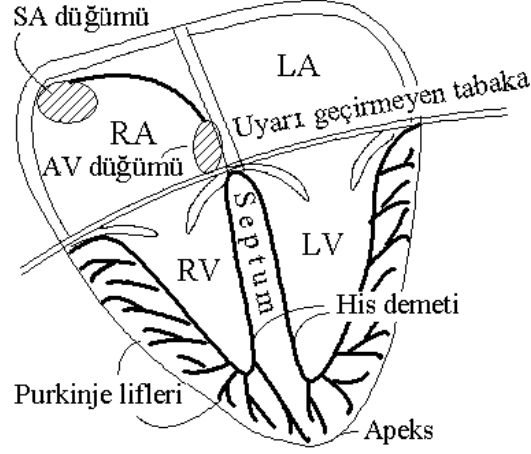
2. ELEKTROKARDİYOĞRAFI VE ARİTMİLER

2.1 Kalbin Fizyolojisi

Bir kalp atımı, kalbin sağ kulakçığının üst taraflarında bulunan ve sinoatrial (veya sinüs) düğüm adı verilen özelleşmiş bir hücre demetinden oluşan bölgenin elektriksel bir uyarı çıkarması ile başlar. Bu bölge kalbin doğal pili olarak bilinir (pacemaker). Sinüs düğümünden çıkan bu uyarı kalbin her iki kulakçığı boyunca ve aşağıya doğru yayılır ve kulakçıklar kasılarak içlerindeki kanı karıncıklara gönderirler. Hayatın devamı için bu elektriksel potansiyel, birbirini izleyen dönemler boyunca hiç durmadan yeniden üretilir. Kalp bu etkinliğin ardından kontraksiyon olarak da adlandırılan mekanik işi yapan bir organdır. Bu yüzden kalp bir biyo-elektromotor kuvvet kaynağı olarak düşünülebilir (Korürek 1996).

Kalp kasının kasılması için ön koşul, hücre membranının elektriksel anlamda uyarımıdır. Elektriksel anlamda uyarımı mekanik harekete dönüştüren ana etmen kalsiyum (Ca^{++}) iyonudur. Dinlenme durumundaki miyokard hücresinde belirli uyarım tarafından başlatılan elektrokimyasal içerikli etkinliğe aksiyon potansiyeli ya da elektriksel sistol denir. Aksiyon potansiyeli, depolarizasyon ve repolarizasyon aşamalarından oluşur. Hücrenin repolarizasyonu izleyerek başlangıç durumundaki özelliklerine dönmesi ile dinlenme potansiyeli (elektriksel diyastol) gelişir.

Kalbin elektriksel dolayısı ile mekanik etkinliğinin belirli bir düzen içinde art arda yinelenebilmesi için, elektriksel periyodun bir döneminde hücreye giren ya da hücreden çıkan iyonun o periyot içinde yerine dönmesi gereklidir. Bu akışı sağlayan iyon geçitleri kalp hücre membranında bulunur.



Şekil 2.1 : Kalbin temel yapısı (Korürek 1996).


2.2 EKG İşareti

2.2.1 Tanım

Kalbin kasılması ve gevşemesi sırasında oluşturduğu elektriksel potansiyelin değişiminin bedenin iletken bir ortam gibi davranmasından yararlanılarak zamana karşı çizdirilip kaydedilmesine, sistem olarak, elektrokardiyografi, bu kaydedilen (görüntülenen) değişimlere Elektrokardiyogram (EKG), elektrokardiyografi sırasında kullanılan ve temelde değiştirilip geliştirilmiş bir galvanometre olan aygıtta ise elektrokardiyograf denir.


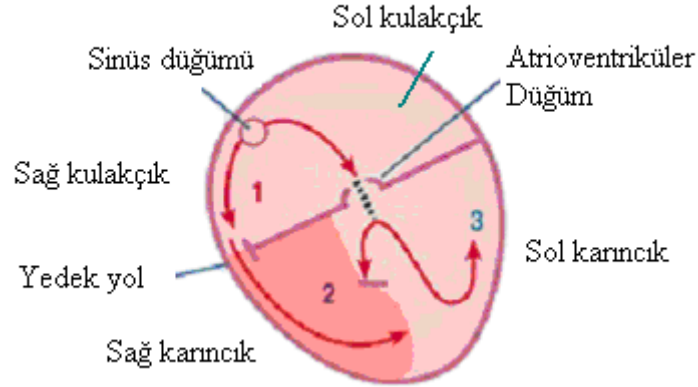
2.2.2 EKG işaretinin bileşenleri

Elektrokardiyogram üzerinde, kalbin elektriksel potansiyeline ilişkin yön, genlik ve zaman içinde değişim gibi bilgiler yer alırlar. Normal EKG, izoelektrik hat üzerinde sıralanan ve P, Q, R, S, T, U adları verilen dalgalardan oluşur. Q, R ve S dalgaları QRS kompleksini oluştururlar (Şekil 2.2).



Şekil 2.2 : EKG işaretini süre (www.vetgo.com).

SA (Sinoatrial) düğümü tarafından üretilen doğal uyarı, ön, orta ve arka internodal yollar aracılığı ile önce sağ kulakçığa, ardından kulakçık septumuna ve son olarak sol kulakçığa yayılır, (Şekil 2.3).



Şekil 2.3 : Kalpte uyarı iletim yolları (www.vetgo.com).

Buna göre sol kulakçığın depolarizasyonu, sağ kulakçığın depolarizasyonundan daha sonra oluşur. Kulakçık depolarizasyonunun elektrokardiyogramdaki karşılığı P dalgasıdır. Elektrokardiyogramdaki PR, daha doğru bir deyiş ile PQ aralığı, SA

düğümünden kaynaklanan uyarının karıncıklara ulaşması için geçen süreyi gösterir. Karıncık depolarizasyonunu yansıtan EKG dalgaları QRS kompleksini oluşturur. QRS aralığı, uyarının karıncıklara yayılma süresidir. QRS kompleksini izleyen T dalgası, karıncık repolarizasyonunu gösterir (Nizam, 2008).

2.3 Aritmiler

Aritmi ritim bozukluğu anlamındadır. Çeşitli kalp hastalıkları neticesinde kalp atış ritminde bozulmalar meydana gelebilir. Bunun neticesinde de aşağıda sıralanan aritmiler ortaya çıkabilir.

Hastalıkların teşhis ve tedavisinde yukarıda anlatıldığı şekilde çok büyük öneme sahip olan EKG analizleri kullanılırken aşağıdaki hususlar da göz önünde bulundurulmalıdır.

- a. İlk EKG'nin tanı koyduruculuk değeri %50'dir. Olguların yaklaşık %50'si ilk EKG ile atlanabilir.
- b. Olguların peş peşe EKG'lerle takibi EKG'nin tanısal değerini %99'lere kadar yükseltebilmektedir.
- c. Önceki bir EKG'nin varlığı tanıda her zaman yardımcı ve hassasiyeti artırıcıdır.
- d. Tek başına EKG'nin normal olması, hiç bir zaman kişinin hasta olmadığını göstermez.

EKG işaretinde, bozucu etkiler, çok küçük genliklere sahip olan P ve T dalgaları ile aynı işaret seviyesinde kalmakta olduğundan bu dalgaların algılanmaları güçleşir. Bunun yerine, nispeten büyük genlikli R dalgalarının varlığı algılanabilir. Bu durumda da R dalgalarının genliği yanında zaman içindeki yeri açısından da inceleme yaparak hastalık teşhisine gidilir (Korürek 1996).

Her aritmi, mikrobilgisayarın teşhis edebilmesine imkân verecek şekilde matematiksel ifadelerle belirlenmelidir. Bunun için, önce, bir takım ön tanımlar ve bunların ifadeleri verilecektir. Genelde, aritmi analizi için kullanılan EKG işaretinde peş peşe gelen R dalgalarının zaman içindeki yerine bakıldığı içindir ki, matematiksel ifadelerde RR_t peş peşe gelen en son iki R dalgası arasında geçen zaman aralığı, RR_{t-1} son RR aralığından bir önceki RR aralığına karşı düşen süredir. AR_t , peş peşe gelen sekiz normal RR aralıklarının ortalamasıdır ve benzer şekilde indisler bu tanım için de kullanılacaktır.

Aritmi teşhisi için sadece RR aralığı yeterli olmamakla birlikte aritmilerle kalp ritmi arasındaki genel ilişki Şekil 2.3'te gösterilmiştir.

Çeşitli kalp rahatsızlıkları sonucu ortaya çıkan aritmilerin en önemlileri aşağıdaki gibi sıralanabilir (Korurek 1996). Tez kapsamında bunlardan normal (N), erken karıncık kasılması (V), erken kulakçık atımı (A), sol dal blok vurusu (L) ve sağ dal blok vurusu (R) şeklinde beş adedi kullanılmıştır.

1) *Bradikardi*: Kalp atış hızının normal alt sınır değerinin altına düşmesidir. Matematiksel olarak, bu hastalık teşhisinde kullanılacak koşul (2.1) ve (2.2) eşitliklerindeki gibidir.

$$RR_t > 1,5 \text{ s} \quad (2.1)$$

$$AR_t > 1,2 \text{ s} \quad (2.2)$$

	RR aralığı
Normal sinus ritmi	
Bradikardi	
Taşikardi	
Asistol	
Eksik Atım	
PVC	
T üzerinde R	
Bigemini	
Trigemini	

Şekil 2.4 : Çeşitli aritmilerde kalp ritmindeki değişim (Tompkins ve diğ. 1981).

2) *Taşikardi*: Kalp atış hızının normal üst sınır değerinin üstüne çıkmasıdır. Matematiksel olarak, bu koşul (2.3) eşitliğindeki gibidir.

$$AR_t < 0,5 \text{ s} \quad (2.3)$$

Kalp atışındaki hızlanma dakikalar, günler veya daha uzun süreler içinde olabilir. Pek çok durumda taşikardi hayatı tehdit etmez; ancak, kişinin sinirli ve gerilimli hissetmesine sebep olur.

3) *Karıncık fibrilasyonu veya asistol*: Uzun bir zaman aralığı içerisindeki QRS kompleksinin yokluğu ile belirlenmektedir.

$$RR_t > 1,6 \text{ s} \quad (2.4)$$

4) *Eksik atım, sinüs tutulması*: RR aralığının, kendisinden önce gelen normal RR aralıkları ortalamasının yaklaşık iki misline eşit olması ile teşhis edilir. Yalnız, bu durumdan sonra farkı kapatacak yönde fazla atımın bulunmaması gerekir. Eğer RR aralığı, ortalama RR aralığının iki katı civarında, ancak 1,5 sn'den az ise 'sinüs tutulması' teşhisi yapılmalıdır. Eksik atım, matematiksel olarak Eşitlik (2.5)'teki gibidir.

$$RR_t \geq 1,9 (AR_{t-1}) \quad (2.5)$$

5) *Erken karıncık kasılması, PVC*: Eğer RR aralığı, bir önceki ortalama RR aralığının 0,9 katından küçük (erken fazlı) ve sonraki periyotta bunu telafi edici yönde gecikmiş kasılmalar (kompanzasyon fazı) mevcut ise erken karıncık kasılması (PVC) olayı detekte edilmiş olur. Ancak, sadece ritim analizi kullanılarak yapılan PVC analizinin bir takım sorunları vardır. Bunlardan ilki, erken vurunun gözlemidir. Bir vurunun ne zaman erken faz ve ne zaman sinüs tutulmasına konu olacağını bilmek zordur. Eğer erken faz tespit edilirse, bunun ortalaması ve aralığı saklanır ve 1 dakikalık zaman aralığında bu bu PVC olaylarından kaç tane geldiğine bakılır. Eğer bu olayların sayısı 10 vuru/dakika'yı geçerse PVC teşhis konulur. Bu durum, matematiksel olarak (2.6), (2.7), (2.8) eşitlikleri ile ifade edilebilir.

$$RR_{t-1} < 0,9 (AR_{t-2}) \quad (2.6)$$

$$RR_{t-1} + RR_t \approx 2 (AR_{t-2}) \quad (2.7)$$

$$PVC \text{ hızı} > 10 / \text{dak.} \quad (2.8)$$

6) *Erken kulakçık kasılması, APC*: Bazı kalp hücrelerinin SA düğümü tarafından uyarılmadan önce kendiliklerinden uyarılması ile oluşmaktadır. Sağlık açısından PVC kadar önemli olmasa da göğüs ve sırt ağrısı gibi problemlere yol açabilir.

- Kalp ritmi ortalama olarak değişmez. Ancak yerel olarak RR aralığı kısalabilir.

- QRS dalga şekli normaldir. Ancak QRS aralığı 0.12 ms'den az olabilir.
- T dalgası şekli normaldir.
- P dalgası şeklinde bozulma görülebilir. Bir önceki T dalgası ile karışabilir.

7) *T üzeri R (R-on-T)* : Çok tehlikeli bir aritmidir. Bu, karıncık repolarizasyon zamanında olan bir erken karıncık kasılmasıdır. T dalgalarını ayırt etmek mümkün olmadığından sadece ritim analizine güvenilmiştir. T dalgaları, RR aralığının ilk 1/3'lük süresinde oluşmaktadır. Böylece bir RR aralığı, kendisinden önce gelen normal işaretlere ait RR ortalamasından 1/3 oranında daha az ve sonrasında telafi edici bir RR varsa, T üzeri R olayı gözlenir. Matematiksel olarak aşağıdaki şekilde belirtilir;

$$RR_t < 0,33 (AR_{t-2}) \quad (2.9)$$

$$RR_t + RR_{t-1} \approx 2 (AR_{t-2}) \quad (2.10)$$

8) *Bigemini*: Eğer peş peşe (en az iki tane) PVC'ler art arda gelirse bigemini bozukluğu ortaya çıkar. Matematiksel olarak (2.11), (2.12), (2.13) ve (2.14) eşitlikleri ile ifade edilir.

$$RR_{t-3} < 0,9 (AR_{t-4}) \quad (2.11)$$

$$RR_{t-3} + RR_{t-2} \approx 2 (AR_{t-4}) \quad (2.12)$$

$$RR_{t-1} < 0,9 (AR_{t-4}) \quad (2.13)$$

$$RR_{t-1} + RR_t \approx 2 (AR_{t-4}) \quad (2.14)$$

9) *Trigemini*: Eğer normal bir darbeden sonra peş peşe iki erken fazlı darbe olur ve bunu takip eden darbe de kompanze edici tipten olursa trigemini teşhis edilir. Matematiksel olarak (2.15), (2.16) ve (2.17) eşitlikleri ile ifade edilir.

$$RR_{t-2} < 0,9 (AR_{t-3}) \quad (2.15)$$

$$RR_{t-1} < 0,9 (AR_{t-3}) \quad (2.16)$$

$$RR_{t-2} + RR_{t-1} + RR_t \approx 2 (AR_{t-3}) \quad (2.17)$$

10) *Ara karıncık kasılması (ekstrasistol yada ara PVC)* : Kompanze edici darbelerin izlemediği erken karıncık kasılması durumudur. Buna göre normal RR aralığında fazladan bir darbe oluşuyor demektir. Bu olay dakikada 10'dan fazla oluyorsa

ekstrasistol teşhisi konur. Matematiksel olarak (2.18), (2.19) ve (2.20) eşitlikleri ile ifade edilir.

$$RR_{t-1} < 0,9 (AR_{t-2}) \quad (2.18)$$

$$RR_{t-1} + RR_t = AR_{t-2} \quad (2.19)$$

$$\text{Ara karıncık kasılması hızı} > 10/ \text{ dak.} \quad (2.20)$$

11) *Erken kulakçık atımları (APB)* : Normal atımlar içinde, birkaç atımda bir RR aralığı önceki ortalama RR aralığının 0,9 katından daha küçük kalır ve izleyen darbe kompanse edici nitelikte değil normal aralığında ise APB olayı ortaya çıkar. Aynı durumda erken kulakçık atımlarının sayısı da dakikada 10'dan fazla ise erken kulakçık atımı teşhisi konulur. Matematiksel olarak erken kulakçık atımları aşağıdaki şekilde modellenebilir;

$$RR_{t-1} < 0,9 (AR_{t-2}) \quad (2.21)$$

$$AR_{t-2} < RR_{t-1} + RR_t < 2AR_{t-2} \quad (2.22)$$

$$\text{APB hızı} > 10 / \text{ dak.} \quad (2.23)$$

12) *Sağ dal blokları ("right bundle branch block", RBBB)*: RBBB aritmisi kalbin elektriksel sisteminde bir bozukluk olduğunu gösterir. Tipik RBBB aritmisinin EKG karakteristiği V1 derivasyonunda geniş QRS kompleks ve terminal R dalgası ve V6 derivasyonunda küçülmüş S dalgası şeklindedir.

RBBB durumunda sağ karıncık sağ dal bloğunda ilerleyen elektriksel uyarı ile direkt olarak uyarılmaz. Bununla birlikte sol karıncık, sol dal bloğundan geçen uyarı ile normal olarak uyarılmaktadır. Daha sonra bu uyarı AV düğümünden geçerek gecikmeli olarak sağ karıncığı uyarır. Bir EKG içerisinde RBBB teşhisi için aşağıdaki karakteristik özellikler bulunmalıdır.

- Kalp ritminin normal olması
- QRS süresinin 120' ms den daha uzun olması
- V1 derivasyonunda terminal R dalgası olması
- V6 derivasyonunda genişlemiş S dalgası olması

RBBB oluşma sıklığı yaş ilerleyince artabilir.


13) *Füzyon ve karıncık füzyonu:* Kalp içersinde farklı odaklardan yayılan uyarıların karşılaşmaları sonucu ortaya çıkan aritmik vurulardır. Uyarılar eęer kulakçıkta karşılaşıyorsa füzyon ve eęer karıncıkta karşılaşıyorsa karıncık füzyonu olarak adlandırılırlar. Füzyon aritmileri, kalbin normal ve normal olmayan aktivitelerinin birleşmesi sonucu oluştuğundan genel olarak R dalga şeklinde yani QRS kısmında bir bozulma olarak gözükürler. Karşılaşan uyarıların kaynağı ve karşılaşma zamanına göre QRS'teki bozulma deęişkenlik gösterebilir.

3. DALGACIK ANALİZİ


3.1 Dalgacık Temelleri

Dalgacık terimi adından da anlaşılacağı gibi “küçük bir dalga” anlamına gelmektedir. Küçük bir dalganın dalgacık sayılabilmesi için genliğinin pozitif ve negatif tarafında en az bir salınım yapması ve hızlı bir şekilde sifira düşmesidir. Bu özellik dalgacık dönüşümünde kullanılacak bir fonksiyonun sahip olması gereken kabul edilebilirlik koşulunun bir benzeridir (You, 1993). Şekil 3.1’de Mucidi Jean Morlet’den dolayı “Morlet dalgacığı” adı verilen bir dalgacık fonksiyonu görölmektedir.

Amaç dalgacık fonksiyonunun ötelenmesi (translation, shifting) ve ölçeklenmesi (dilation, scaling or compressing) ile elde edilen yavru dalgacıkları (daughter wavelet) kullanarak bir işareti temsil edebilmektir. Kaba ölçeklerden başlayarak iterasyonla git gide işarete yaklaşılarak ince ayar yapılır ve işaretin en iyi şekilde temsil edilmesi sağlanabilir. Şekil 3.2’de b ötelemeyi, a ölçeklemeyi göstermek üzere; çeşitli ötelenmiş ve ölçeklenmiş dalgacıklar görölmektedir. Dikkat edilirse bu öteleme ve ölçeklemeler ana dalgacığın salınım sayısını değıştirmez (Lecutai, 1997).



Şekil 3.1 : Morlet Dalgacığı.



Şekil 3.2 : Ötelenmiş ve ölçeklenmiş Morlet dalgacı.

3.2 Dalgacık Dönüşümü

Dalgacık dönüşümü bir fonksiyonu çekirdek bir fonksiyondan türetilmiş fonksiyonlarla entegrali alınarak dönüştürülmesidir (Combes, 1989). Çekirdek fonksiyona *ana dalgacık* (“mother wavelet”) denir. Bölümün başında da değinildiği gibi türetilmiş fonksiyonlara *yavru dalgacık* (“daughter wavelet”) denir. Bölümün başında bahsedilen kabul edilebilirlik koşulunun yanı sıra bir fonksiyonun entegrali de sıfır oluyor ise (sıfır frekanslı bileşeni sıfır, veya d.c. değeri sıfır) *Grossmann-Morlet* kabul edilebilirlik koşulunu sağlıyor denir. Diğer bir ifadeyle; eğer bir fonksiyon $h \in L^2(R)$ için; $h(t)$ fonksiyonunun Fourier transformu $H(\omega)$ olmak üzere;

$$c_k = \int_{-\infty}^{\infty} \frac{|H(\omega)|^2}{|\omega|} d\omega < \infty \quad (3.6)$$

eşitliğini sağlıyorsa kabul edilebilir bir fonksiyondur denir (GM, 1984). Kabul edilebilirlik koşulunu sağlayan her fonksiyon bir ana dalgacık olabilir. Bu da $H(0) = 0$ ise mümkündür. Bir $f \in L^2(R)$ fonksiyonunun $h(t)$ dalgacığına göre dalgacık dönüşümü, * karmaşık eşleniği göstermek üzere;

$$W_f(a, b) = \int_{-\infty}^{\infty} f(t)h_{a,b}^*(t)dt \quad (3.7)$$

olarak tanımlanır. Yavru dalgacıklar ana dalgacıktan öteleme ve ölçekleme ile elde edilirler.

$$h_{a,b}(t) = \frac{1}{\sqrt{a}}h\left(\frac{t-b}{a}\right) \quad (3.8)$$

($a > 0$) ölçekleme faktörü ve b de öteleme faktörüdür.

3.2.1 Morlet dalgacık fonksiyonu

Morlet fonksiyonu esasında Fourier'in Gauss penceresiyle çarpılmasından elde edilir

$$h(t) = \exp(j\omega_0 t) \exp\left(-\frac{t^2}{2\sigma}\right), \sigma > 0 \quad (3.9)$$

Gerçel kısmı bir Cos-gaussian, sanal kısmı ise Sin-gaussian fonksiyonudur. $\varphi_R(\cdot)$ reel kısmı, $\varphi_I(\cdot)$ sanal kısmı göstermek üzere t kadar ötelenmiş ve d ile ölçeklenmiş Morlet yavru dalgacıklarının reel ve sanal kısımları Eşitlik 3.10'daki gibidir.

$$\varphi_{d,t}(x) = \varphi_{R,d,t}\left(\frac{x-t}{d}\right) + j \cdot \varphi_{I,d,t}\left(\frac{x-t}{d}\right), d \in R \setminus \{0\}, t \in R$$

$$\begin{cases} \varphi_{R,d,t}(x) = \cos\left[5 \cdot \frac{(x-t)}{d}\right] e^{-\frac{(x-t)^2}{2\sigma d^2}}, \\ \varphi_{I,d,t}(x) = \sin\left[5 \cdot \frac{(x-t)}{d}\right] e^{-\frac{(x-t)^2}{2\sigma d^2}} \end{cases} \quad (3.10)$$

Morlet'in fourier dönüşümü eşitlik 3.11'deki gibidir.

$$H(\omega) = \sqrt{\frac{\pi}{2}}(\exp[-0.5(\omega - \omega_0)^2] + \exp[-0.5(\omega + \omega_0)^2]), \sigma = 1 \quad (3.11)$$

Aslında Morlet kabuledilebilirlik koşulunu sağlamaz, çünkü $H(0)$ değeri sıfır değildir.

$$H(0) = \sqrt{2\pi} \exp(-0.5\omega_0^2) \neq 0 \quad (3.12)$$


Bununla beraber yeterince büyük ω_0 deęerleri için ($\omega_0 \geq 5$) $H(0)$ sifıra çok yaklařır ($\omega_0 = 4$ için $H(0) = 0.00084$) ve nümerik hesaplarda sifır kabul edilebilir.

3.2.2 Meksika řapkası dalgacık fonksiyonu

Matematikte Meksika řapkası olarak bilinen bu dalgacık Gauss fonksiyonunun normalize edilmiř ikinci türevidir. Hermitian tipi sürekli dalgacıklardan birisidir. Dalgacığın eřitlięi ařaęıdaki gibidir.

$$\varphi(t) = \frac{1}{\sqrt{2\pi}\sigma^3} \left(1 - \frac{t^2}{\sigma^2}\right) e^{-\frac{t^2}{2\sigma^2}} \quad (3.13)$$

řekil 3.3'te görüldüęü gibi řekli Meksika řapkasını andırmaktadır. Bu sebepten ötürü Meksika řapkası olarak adlandırılmıřtır. Ancak teknik terminolojide Ricker Dalgacığı adıyla da bilinir (Brinks, 2008).



řekil 3.3 : Meksika řapkası dalgacığı.

4. YAPAY SİNİR AĞLARI

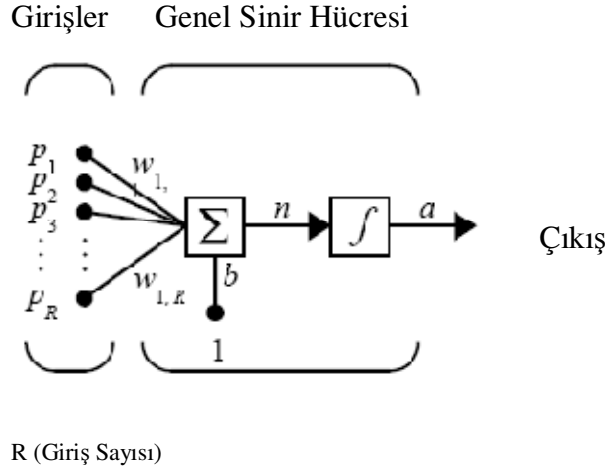
4.1 Yapay Sinir Ağının Tanımı

Sinir ağları, biyolojik sinir sistemlerinden esinlenerek tasarlanan ve nöron ismi verilen hesaplama elemanlarının paralel bir şekilde çalışmasından meydana gelir. Belirli bir fonksiyonu gerçekleştirmek için bir sinir ağı, elemanları arasındaki bağlantıların (ağırlıkların) değerleri ayarlanarak eğitilmektedir. Genelde, yapay sinir ağları eğitilerek verilen belirli bir girişe karşılık arzu edilen çıkışı elde ederler. Bu durum Şekil 4.1’de verilmiştir. Ağın çıkışı arzu edilen hedefe ulaşmaya kadar çıkış ile hedef karşılaştırılarak ağın eğitimi (ağırlık değerlerinin ayarlanması) gerçekleştirilir. En basit tanımıyla yapay sinir ağları, bilinen en iyi eğri uydurma tekniklerinden birisidir (Dokur, 1999).

Yapay sinir ağı, aşağıdaki tanımlamaları ve sınırlamaları içeren paralel bilgi işleme özelliğine sahip yönlü bir graftır (Hecht-Nielsen, 1990).

- a) Yönlü grafin düğümleri *işlem elemanı* olarak tanımlanır.
- b) Yönlü dallar bağlantılara karşılık düşer ve tek yönlü işaret iletim yolu olarak çalışırlar.
- c) Her bir işlem elemanı, belirli bir sayıda giriş bağlantısına sahiptir.
- d) Her bir işlem elemanı, belirli bir sayıda çıkış bağlantısına sahiptir. Ancak çıkış işaretlerinin değeri aynı olmalıdır.
- e) İşlem elemanları yerel belleklere sahip olabilir.
- f) Her işlem elemanı, giriş işaretini ve yerel belleği kullanan bir transfer fonksiyonuna sahiptir. Bu fonksiyon işlem elemanının çıkış değerini oluşturur. Transfer fonksiyonu sürekli veya ayırık olarak çalıştırılabilir. Ayırık çalıştırma modunda fonksiyon, bir aktivasyon işareti ile kontrol edilir.
- g) Yönlü bağlantı ve işlem elemanlarının bir araya gelmesi ile oluşan yapıya, yapay sinir ağı (YSA) ismi verilir. Bu yapı, dış çevreden giriş bağlantıları yolu ile işaret alır ve çıkış bağlantıları yolu ile işaret gönderir.

Şekil 4.1’de işlem elemanının iç yapısı gösterilmiştir. Şekil 4.2’de de genel bir YSA yapısı gösterilmiştir. İşlem elemanının transfer fonksiyonu, diğer elemanlardan ve yerel belleğinden gelen bilgileri giriş olarak alır. Aktivasyon fonksiyonunun çıkışı, diğer elemanlara gönderilmek üzere kopyalanır.



Şekil 4.1 : YSA İşlem elemanının (nöronun) yapısı (Nizam, 2008).

p_i 'ler giriş olmak üzere YSA işlem elemanında gerçekleştirilen işlemler aşağıdaki gibidir.

$$n = \sum_{i=1}^R w_i p_i + b \quad (4.1)$$


$$a = f(\sum_{i=1}^R w_i p_i + b) \quad (4.2)$$

Burada p_i , giriş vektörünün i. elemanını; n , aratoplayıcı çıkışı; w_i , aratoplam ile giriş düğümleri arasındaki i. dal ağırlığını; a , hücre çıkışını; b , hücrenin kutuplama değerini; $f(\cdot)$ ise kırpıcı olarak ta çalışan ve lineer olmayan transfer fonksiyonunu temsil etmektedir.

Yapay sinir ağları, katman olarak isimlendirilen alt kümeler içinde aynı yapıda işlem elemanlarına sahiptir. Bu alt kümeler içindeki tüm işlem elemanları aynı transfer fonksiyonunu kullanır. Aynı katman içindeki işlem elemanları birbirleriyle veya diğer katmandaki elemanlar ile bağlantı oluşturabilir.

YSA birimi sınıflamada en çok kullanılan yöntemlerden biridir. Rumelhart ve diğ. (1998), Foo ve diğ (2002) geriye yayılım (GY) temelli YSA'lar kullanarak aritmi teşhisi uygulamaları gerçekleştirmişlerdir.

Palreddy ve diğ. (1997) birden fazla YSA kullanmışlardır. İlk seviyede her sınıflayıcı belli özellikler için optimize edilmiştir. İkinci seviyedeki sınıflayıcı girişinde birinci seviye çıkışları bir birleştirme kuralı ile birleştirilmiştir. Sistemin genel çıkışı ikinci seviye sınıflama sonunda oluşturulmuştur.



Şekil 4.2 : Yapay Sinir Ağının genel yapısı (Nizam, 2008).

4.2 Çok Katmanlı Almaç Ağı (ÇKA, “Multi-layer Perceptron”)

İşlem elemanı, transfer fonksiyonu ve öğrenme ile ilgili kavramaların daha iyi anlaşılması için, yapay sinir ağlarında en temel algılayıcı (*almaç*) yapısını inceleyelim (Hecht-Nielsen, 1990). Yapay sinir ağlarında çok çeşitli ağ yapıları ve modelleri vardır. En çok kullanılan ağ yapılarından birisi ÇKA'dır. Bu ağda bilginin akışı ileri yönlüdür. Öğrenme ve eğitime algoritması olarak genelde türeğe dayalı geriye yayılım (“back propagation”, GY) algoritmaları tercih edilir. Burada, nöronlar 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 (Şekil 4.2). Son katman çıkış katmanı olarak da isimlendirilir. Giriş ile çıkış katmanı arasında yer alan katmanlar gizli katman (“hidden layer”) olarak da anılmaktadır. Bu durumda giriş ile çıkış arasında paralel bir matematiksel ilişki kurulmuş olur. Uygun bir öğrenme algoritması ile ağırlık değerleri ağın arzu edilen çıkışını verecek şekilde ayarlanmaktadır.

4.2.1 Geriye yayılım (“back-propagation”) algoritması

Geriye yayılım algoritmasının birçok farklı gerçekleştirme yöntemi vardır. En basit şekli ağırlık ve kutuplama (“bias”) vektörlerinin performans fonksiyonunun en hızlı azalma yönüne göre değiştirilmesidir. Bu şekilde algoritmanın tek bir döngüsü aşağıdaki formülle ifade edilebilir.

$$w_{k+1} = w_k - \alpha_k g_k \quad (4.3)$$

Burada, w_k ağırlık elemanının k anındaki değerini, g_k k anındaki eğimi (gradyenti), α_k ise öğrenme oranını temsil etmektedir.

Almaç, Şekil 4.1’de gösterilen birden fazla girişi, en az bir çıkışı, bir transfer fonksiyonu ve giriş sayısı kadar yerel bellek elemanı olan en basit yapıda yapay sinir ağıdır. Eşitlik 4.1’de algılayıcının matematiksel ifadesi verilmiştir.

Eğitim işlemi ile algılayıcıdaki sadece w_i ağırlık elemanları değiştirilir. Bu elemanlar çoğu zaman sinir hücresinin *ağırlık vektörü* olarak tanımlanır. Hücrenin ağırlıkları önceden belirlenen amaç ölçütünü sağlaması için bir eğitim algoritması kullanılarak değiştirilir. Öğrenme işlemini, bu amaç ölçütünü en iyi sağlayan w_i ağırlık vektörünü bulmaya doğru adım adım yaklaşma olarak tanımlayabiliriz.


Öğrenme algoritması, eğitim kümesinden alınan sınıf dağılım bilgisini kullanarak, amacı sağlayan optimum w_i değerlerini araştırır. Ancak, amaç ölçütünün her zaman bir düğüm (hücre) ile sağlanması mümkün olmaz; bu ölçüt için çok sayıda düğüm gerekebilir. Ağ, incelenen problem için amaç ölçütünü sağlayabilecek yapıya sahip olmalıdır; aksi takdirde bu ağ için hiçbir eğitim algoritması istenilen sonucu veremeyecektir.

4.3 İstatistiksel Sinir Ağları

Genel Doğrusal Öngörü Sinir Ağları (GRNN, “General Regression Neural Networks”) ve İstatistiksel Sinir Ağları (PNN, “Probabilistic Neural Network”) uygulamaları farklı olmalarına rağmen kavramsal olarak k -En Yakın Komşu ağlarına çok benzerler. Bu ağların dayandığı temel dayanak noktası belirli bir giriş için arzu edilen çıkış değerinin kendisine yakın diğer girişlerin arzu edilen çıkış değerine yakın olacağıdır. Bilindiği gibi En Yakın Komşu ağlarında, çıkışı bilinmeyen bir giriş için arzu edilen çıkış, eğitim kümesinde kendisine en yakın girişin arzu edilen

çıkışıdır. ‘k-En Yakın Komşu’ ağları ‘En Yakın Komşu’ ağlarının biraz daha genişletilmiş halidir. Bu ağ yapısında çıkışı bilinmeyen bir girişin arzu edilen çıkışı bulunurken öncelikle kendisine en yakın K tane giriş belirlenir. Bu giriş düğümlerinin arzu edilen çıkışları içerisinde en çok tekrar eden çıkış yeni düğümün arzu edilen çıkışı olur (Url-2).

Aşağıdaki şekilde çıkışı iki ayrıık değerden (negatif veya pozitif) birini alabilen bir ağın eğitim kümesinin dağılımı gösterilmiştir. Bu ağda arzu edilen çıkış x ve y girişlerinden elde edilmektedir. Arzu edilen çıkışlar ‘-’ ve ‘■’ sembolleri ile ifade edilmiştir. Çizgi (‘-’) sembolü negatif çıkışı, kare (‘■’) sembolü ise pozitif çıkışı ifade etmektedir. Üçgen (‘Δ’) simgesi ile gösterilen giriş ağa uygulandığında arzu edilen çıkış negatif mi yoksa pozitif mi olacaktır?




Şekil 4.3 : k-En Yakın Komşu ağlarında iki boyutlu bir noktanın arzulan çıkış değerinin bulunması (Url-2).

Şekil 4.3'te de görüldüğü gibi üçgen nerede ise çizginin tam üzerinde yer almaktadır. Fakat üçgenin altında yer alan çizgi diğer çizgilerin dağılımı düşünüldüğünde müstesna sayılabilecek bir yerdedir. k-En Yakın Komşu algoritmasının bu üçgen için vereceği karar k komşuluk sayısına bağlıdır. Eğer 1-En Yakın Komşu uygulanırsa

üçgen için negatif kararı çıkacağı aşikârdır. Fakat 9-En Yakın Komşu uygulanırsa üçgenin etrafındaki 8 adet kare ağırlık basacak ve bitişikteki çizginin etkisini dengeleyecektir. İstatistiksel Sınır Ağları ve Genel Doğrusal Öngörü Ağları da dâhil olmak üzere, Radyal Tabanlı Fonksiyon (RBF) kullanan tüm ağlar bu temel mantık üzerine kurulmuştur. Bu ağlar k-En Yakın Komşu mantığını genelleştirmiş ve eğitim kümesinde yer alan bütün noktaların arzu edilen çıkışa belli bir oranda etki etmesini sağlamışlardır. Her nokta için diğer noktalara olan mesafe bulunur. RBF ile her bir noktanın sonuç üzerindeki etkisi, ele alınan nokta ile arasındaki radyal mesafeye bağlı olarak değişir. Bir nokta ne kadar uzakta ise sonuca olan etkisi de o kadar düşer (Url-2).

4.3.1 Radyal tabanlı fonksiyon ağları


Radyal Tabanlı Fonksiyon Ağlarında (“Radial Basis Functions”, RBF) temel fikir, bir grup radyal tabanlı fonksiyonunu arzu edilen çıkışa yaklaşıp yaklaşacak şekilde ağırlandırarak toplamaktan ibarettir. RBF, YSA yapısında üç katmanlı bir ağırdır. Giriş katmanı giriş vektörleri ile, çıkış katmanı da çıkıştaki örüntülerin sınıfı ile ilişkilidir. Böylelikle tüm yapı, gizli katmanın yapısı ve gizli katman ile çıkış katmanı arasındaki ağırlıkların belirlenmesine indirgenir. Gizli katmandaki nöronların aktivasyon fonksiyonları bir C_j merkezi ve σ_j bant genişliği ile belirlenir. Aktivasyon fonksiyonu $\varphi(\cdot)$, Eşitlik 4.4’te gösterilen bir Radyal Tabanlı Fonksiyondur. Bu fonksiyonlara radyal tabanlı denmesinin nedeni parametre olarak girişle merkez arasındaki radyal mesafeyi almalarıdır. RBF olarak kullanılabilen bir çok fonksiyon olmakla beraber en çok bilinen Gauss fonksiyonudur. Şekil 4.4’de Gauss fonksiyonu gösterilmiştir (Bolat, 2005).



Şekil 4.4 : Gauss fonksiyonu ($\sigma = 1, C_j = (0,0)$).

$$\varphi_j(\mathbf{X}) = \exp\left(-\frac{\|\mathbf{x}-\mathbf{c}_j\|^2}{2\cdot\sigma_j^2}\right) \quad (4.4)$$

Giriş sayısı n olursa RBF de n boyutlu olacaktır. Bir giriş vektörüne (giriş düğümüne) karşı nöronun arzu edilen çıkış değeri, bütün giriş düğümlerine olan ağırlıklandırılmış mesafelerin toplamından elde edilir. RBF'nin merkezi her zaman giriş düğümü olarak ele alınır. σ parametresi RBF'nin saçılımını belirler ve 'yumuşatma parametresi' olarak bilinir. RBF ne kadar çok saçılırsa (σ ne kadar büyükse) uzaktaki düğümlerin toplam mesafe üzerindeki etkisi o kadar artar. Dolayısıyla küçük σ değerleri seçiciliği artırır. Görüldüğü gibi Şekil 4.4'teki Gauss eğrisi σ 'nın daha küçük olduğu Şekil 4.5'teki Gauss eğrisinden daha yayvandır.



Şekil 4.5 : Gauss fonksiyonun çıkışı. ($\sigma = 0.2, C_j = (0,0)$).

w_{ij} gizli nöron i ve çıkış nöronu j arasındaki ağırlık katsayısı olmak üzere çıkış katmanındaki j . nöronun çıkışı için genel eşitlik ise şu şekildedir.

$$s_j(\mathbf{X}) = \sum_{i=1}^K w_{ij} \varphi_i(\mathbf{X}) + b_j \quad (4.5)$$

4.3.2 Genel doğrusal öngörü sinir ağları

Genel Doğrusal Öngörü Sinir Ağları (General Regression Neural Networks - GRNN) RBF ağlarının özel bir durumudur. Bu ağlarda merkez ve bant genişliği eğitim kümesinin deterministik fonksiyonları olarak belirlenir. Bu nedenle bu tür ağlarda eğitim tek bir adımda gerçekleşir ve iteratif yöntemler kullanılmaz.

GRNN ağlarda bir \mathbf{x}_i eğitim girişi, ağdaki Gauss çekirdeklerden birinin merkezi olarak atanır. Herhangi bir giriş vektörü $\underline{\mathbf{x}}$ için i . RBF biriminin çıkışı $\beta(\cdot)$, şu şekilde hesaplanır:

$$\beta_i = \exp \left[-\frac{(\underline{\mathbf{x}} - \underline{\mathbf{x}}_i)^T (\underline{\mathbf{x}} - \underline{\mathbf{x}}_i)}{2 \cdot \sigma^2} \right] \quad (4.6)$$

Burada σ bir yumuşatma parametresidir. \mathbf{y}_i , eğitim kümesindeki i . girişe ($\underline{\mathbf{x}}_i$) ilişkin ağın hedef çıkışı olmak üzere, herhangi bir $\underline{\mathbf{x}}$ girişi için ağın çıkışı \mathbf{y} , şu şekilde hesaplanır:

$$\mathbf{y} = \sum_{i=1}^K \alpha_i \mathbf{y}_i \quad (4.7)$$

α katsayıları ise şu şekilde hesaplanır:

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^K \beta_i} \quad (4.8)$$

Eğer giriş vektörü \underline{x} , herhangi bir \underline{x}_i eğitime vektörüne yakın ise, \underline{x}_i 'ye ilişkin α_i en büyük olacak ve arzu edilen çıkış \underline{y} , \underline{x}_i 'ye ilişkin \underline{y}_i 'ye yaklaşacaktır. (Bolat, 2005)

4.3.3 İstatistiksel sinir ağları

İstatistiksel Sinir Ağları (Probabilistic Neural Network – PNN) Bayes-Parzen kestiriciler olarak da bilinir. K_1 ve K_2 sınıflarından birine ait, m-boyutlu bir \underline{x} vektörü olsun. K_1 ve K_2 sınıflarına ait olasılık yoğunluk fonksiyonları $F_1(\underline{x})$ ve $F_2(\underline{x})$ olsun. P_1 ve P_2 , K_1 ve K_2 sınıflarının görülme olasılığı, L_1 , \underline{x} vektörünün K_1 sınıfına ait iken K_2 olarak yanlış sınıflanma oranı (maliyet fonksiyonu) ve L_2 'de \underline{x} vektörünün K_2 sınıfına ait iken K_1 olarak yanlış sınıflanma oranı olmak üzere, Bayes Teoremi'ne göre \underline{x} vektörü,

$$\frac{F_1(\underline{x})}{F_2(\underline{x})} > \frac{L_1 P_2}{L_2 P_1} \quad (4.9)$$

eşitsizliği doğru ise K_1 , eşitsizliğin tersi doğru ise K_2 sınıfına aittir. Buradan görüleceği gibi, $F_1(\underline{x})$, $F_2(\underline{x})$, L_1 , ve L_2 'nin bilinmesi durumunda \underline{x} vektörünün en yüksek olasılıkla hangi sınıfa ait olduğu tespit edilebilir (Specht, 1988). n eğitim kümesindeki veri sayısı, m giriş vektörlerinin boyutu, i örüntü numarası ve σ ise ayarlanabilir bir yumuşatma parametresi olmak üzere; PNN'lerde sınıflara ait yoğunluk fonksiyonları Parzen pencereleri (Parzen, 1962) kullanılarak aşağıdaki şekilde bulunur:

$$F(\underline{x}) = \frac{1}{(2\pi)^{m/2} \sigma^m} \cdot \frac{1}{n} \cdot \sum_{i=1}^n \exp \left[-\frac{(\underline{x}-\underline{x}_i)^T (\underline{x}-\underline{x}_i)}{2 \cdot \sigma^2} \right] \quad (4.10)$$

Bahsi geçen RBF ağlarında yumuşatma parametresi σ parametresi, global alınabileceği gibi yerel de alınabilir. Her bir giriş parametresi için farklı alınması durumunda PNN/GRNN ağlarında eğitim süresi çok uzar. Optimum sigma parametresinin bulunması için (Masters & Land, 1997) ve (Specht, 1988)'te bahsedilen çalışmalar vardır. Ancak (Specht, 1962)'te belirtildiği gibi sigmadaki küçük değişiklikler ağın performansını çok ciddi derecede etkilemez. Bu yüzden tatmin edici sigma değerleri kaba yaklaşımlarla bulunabilir. Beşinci bölümde bahsedileceği gibi (Masters & Land, 1997)'in GRNN ağlarının eğitimi ile ilgili çalışmasında bahsedilen yöntem kullanılarak en uygun sigma değerleri elde edilmeye çalışılmıştır.

5. DALGACIK AĞLARI (WAVENET) VE UYGULAMALARI


5.1 Tanım

3. bölümde anlatılan dalgacıklar ile dördüncü bölümde anlatılan yapay sinir ağları birleştirilirse *dalgacık ağları* veya *adaptif dalgacık ağları* adı verilen yeni bir ağ türü ortaya çıkar. Dalgacık ağlarında iki temel evre vardır: ağın kendi kendini yeniden oluşturması ve hatanın en aza indirgenmesi. Birinci evrede işareti temsil edecek ağ yapısı elde edilir. Ağ ilerledikçe saklı katmanlar, işaretin bulunduğu zaman ve frekans aralıklarını daha iyi kavrayacak şekilde yeniden düzenlenir. Bazı dalgacık ağları algoritmalarında ötelemeler, ölçeklemeler ve düğüm katsayıları her iterasyonda yenilenirken (Lecutai, 1997) bazılarında sadece yapay sinir ağı tarafındaki parametreler yenilenir (Lin ve diğ., 2008). Bu çalışmada ikinci yöntem kullanılacaktır. Yani ağ çalışmaya başladıktan sonra sadece yapay sinir ağı kısmında daha sonra bahsedilecek olan σ parametresi güncellenecektir.

5.2 Geliştirilen Uygulamanın Yapısı

5.2.1 Adaptif istatistik dalgacık ağı (AİDA)

Adaptif İstatistik Dalgacık Aağı temelde iki evreden oluşur: Dalgacık dönüşümü ile işaretin zaman ve frekans domeninde yüksek çözünürlükte temsili sağlanır ve probabilistik yapay sinir ağı (“Probabilistic Neural Network”, PNN) ile sınıflama ve ince ayar yapılır (Lin ve diğ., 2008).



Şekil 5.1 : Adaptif İstatistik Dalgacık Ağı.

Şekil 5.1’ de ikinci kısımda saklı katman, toplam ve çıkış düğümleri görülmektedir. $\varphi_i (i = 1, 2, 3, \dots, n)$, n giriş vektörlerinin boyutu olmak üzere, i . dalgacık düğümünü göstermektedir. Saklı katman düğüm sayısı K aynı zamanda eğitim kümesindeki giriş vektör sayısıdır. $H_k (k = 1, 2, 3, \dots, K)$ saklı katmandaki k . düğümü göstermektedir. S_j , j . toplam düğümünü ve $O_j (j = 1, 2, 3, \dots, m)$ ise j . çıkış düğümünü göstermektedir. Çıkış düğüm sayısı m saklı katman düğüm sayısına (K) eşit alınmıştır. w_{ki}^{WH} k . saklı düğüm ile i . dalgacık düğümünü bağlayan bellek elemanları ve w_{jk}^{HS} j . toplama düğümü ile k . saklı katman düğümünü bağlayan ağırlık katsayıları eğitim kümesindeki ağ ikililerini oluşturur. (Masters ve Land, 1997), (Lin ve diğ., 2008).

$X(k) = [x_1(k), x_2(k), \dots, x_i(k), \dots, x_n(k)]$; $k = 1, 2, 3, \dots, K$ giriş vektörü için sırasıyla ağırlık eşitlikleri aşağıdaki gibidir:

Dalgacık fonksiyonu ($\varphi(\cdot)$); üçüncü bölümde ele alınan ana dalgacık fonksiyonu Morlet olarak alındığında φ yavru dalgacık fonksiyonu (d ölçekleme ve t öteleme olmak üzere), Eşitlik 5.1'deki gibidir.

$$\varphi_i(x_i(k)) = \cos \left[\frac{5 \cdot (x_i(k) - t_i)}{d_i} \right] e^{-\frac{(x_i(k) - t_i)^2}{2\sigma d_i^2}} \quad (5.1)$$

k. saklı düğüm fonksiyonu, σ genel anlamda Morlet ana dalgacığının standart sapması olmak üzere, Eşitlik 5.2'deki gibidir. Her saklı katman düğümü için aynı σ değeri kullanılmıştır ($\sigma_1 = \sigma_2 = \dots = \sigma_k = \dots = \sigma_K = St.$).

$$H_k = \exp \left[-\sum_{i=1}^n \frac{(\varphi_i(x_i) - w_{ki}^{WH})^2}{2\sigma_k^2} \right] \quad (5.1)$$

Toplama düğüm fonksiyonu ($s(\cdot)$); Eşitlik 5.3'deki gibidir.

$$s(\varphi) = \sum_{k=1}^K w_{jk}^{HS} H_k \quad (5.2)$$

Çıkış düğüm fonksiyonu ($O_j(\cdot)$); $j= 1,2,3, \dots, m$ Eşitlik 5.4'teki gibidir.

$$O_j(\varphi) = \frac{\sum_{k=1}^K w_{jk}^{HS} H_k}{\sum_{k=1}^K H_k} = \frac{s(\varphi)}{h(\varphi)} \quad (5.2)$$

Bununla beraber optimum bir sigma değeri bulmak mümkün değildir ve yapılması gereken her adımda σ_k değerini güncellemektir. Optimum σ_k değerinin karesel hata olarak alınacak olan hedef fonksiyonunun değerini en aza indirmesi beklenmektedir (Masters ve Land, 1997).

$$e_j(\varphi, T) = [T_j - O_j(\varphi)]^2 \quad (5.3)$$

$$\frac{\partial e_j(\varphi, T)}{\partial \sigma_k} = 2[T_j - O_j(\varphi)] \frac{\partial O_j(\varphi)}{\partial \sigma_k} \quad (5.4)$$

$$= 2[T_j - O_j(\varphi)] \left[\frac{\frac{\partial s(\varphi)}{\partial \sigma_k} - O_j(\varphi) \frac{\partial h(\varphi)}{\partial \sigma_k}}{h(\varphi)} \right]$$

$$\frac{\partial s(\varphi)}{\partial \sigma_k} = 2 \left[\sum_{k=1}^K w_{jk}^{HS} H_k \right] \left[\frac{(\varphi_i(x_i) - w_{ki}^{WH})^2}{2\sigma_k^3} \right] \quad (5.5)$$

$$\frac{\partial h(\varphi)}{\partial \sigma_k} = 2 \left[\sum_{k=1}^K H_k \right] \left[\frac{(\varphi_i(x_i) - w_{ki}^{WH})^2}{2\sigma_k^3} \right] \quad (5.6)$$

Giriş vektörü X 'in beklenen çıkış değeri T_j , ve tabii ki $\sigma_k \neq 0$.

Yaklaşma parametresi σ_k 'nın güncellenmesinde gradyan metodu kullanılacaktır.

$$\sigma_k(p+1) = \sigma_k(p) + \mu \frac{\partial e_j(\varphi, T)}{\partial \sigma_k} \quad (5.7)$$

μ öğrenme katsayısını, p 'de iterasyon sayısını gösterir. Algoritma aşağıda detaylandırılacağı gibi iki evreden oluşur: Öğrenme evresi ve tekrar (anımsama) evresi.

Öğrenme Evresi: Birinci adımda, eğitim kümesindeki her bir örnek için $X(k) = [x_1(k), x_2(k), \dots, x_i(k), \dots, x_n(k)]$, $k = 1, 2, 3, \dots, K$, $i = 1, 2, 3, \dots, n$ dalgacık katmanı φ_i ile saklı katman H_k arasındaki w_{ki}^{WH} bağlantıları aşağıdaki eşitlikler yardımıyla bulunur.

$$\begin{cases} \varphi_i(k) = \cos \left[\frac{5(x_i(k) - t_i)}{d_i} \right] e^{-\frac{(x_i(k) - t_i)^2}{2\sigma d_i^2}} \\ x_i = V(i), t_i = V_{nor}(i) \\ w_{ki}^{WH} = \varphi_i(k) \end{cases} \quad (5.8)$$

d_i bahsedegelen ölçekleme değerini, $d_i \in Z$; x_i , sınıfı belirlenecek olan ve V ile gösterilen QRS kompleksinden örneklenmiş vektör, t_i öteleme parametreleri, hastanın normal QRS kompleksi V_{nor} ; örnekleme sayısı n ; ve $w^{WH} = [w_{ki}^{WH}]$ k 'ya n boyutunda matristir. İkinci adımda saklı katman düğümü H_k ile çıkış düğümü O_j arasındaki w_{jk}^{HS} bağlantı katsayıları bulunur.

$$w_{jk}^{HS} = \begin{cases} 1 \\ 0 \end{cases} (j = 1, 2, 3, \dots, m) \quad (5.9)$$

w_{jk}^{HS} matrisi eğitim kümesinin elemanları ait oldukları sınıflara tekabül ederse 1 etmezse 0 değerini alır. Saklı katman H_k ile toplam katmanı arasındaki bağlantı katsayıları 1 yapılır.

Tekrar Evresi: Adım 1) Ağ katsayıları w_{ki}^{WH} ve w_{jk}^{HS} 'leri al


Adım 2) Test vektörü $X = [x_1, x_2, \dots, x_i, \dots, x_n]$ ağa uygula. Dalgacık düğümü olan φ_i 'yi hesapla,

$$\varphi_i(x_i) = \cos \left[\frac{5(x_i - t_i)}{d_i} \right] e^{-\frac{(x_i - t_i)^2}{2\sigma d_i^2}} \quad (5.10)$$

Adım 3) Eşitlik 5.1'i kullanarak H_k 'nın değerini hesapla. Eşitlik 5.7'yi kullanarak optimum σ_k 'yi bul. Eşitlik 5.2'yi kullanarak çıkış O_j değerini bul. (Lin ve diğ., 2008)

6. GERÇEKLEŞTİRİLEN YÖNTEMİN UYGULAMASI

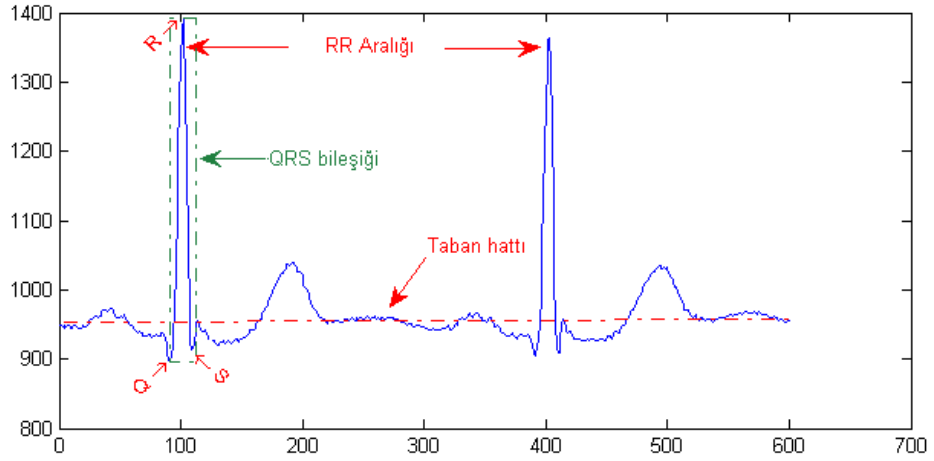
Tez kapsamında yapılan çalışma Şekil 6.1’de gösterildiği gibi üç kısımdan oluşmaktadır. 1) Önışlemler 2) RR aralığının belirlenmesi 3) Dalgacık ağı ve ÇKA ile sınıflama. Klasik yapay sinir ağıları metotlarında sınıflayıcıya sokulacak giriş vektörleri önceden öznitelik çıkarma olarak bilinen bir evreden geçmektedir. Bu evrede öznitelik adı verilen işaretin ayırt edici parametreleri gelişmiş algoritmalar kullanılarak belirlenmektedir. Ancak Dalgacık Ağlarında işaretin zaman temsili doğrudan ağa giriş olarak verildiğinden ve Dalgacık Ağından elde edilecek sonuçlar ÇKA ile kıyaslanacağından ötürü ÇKA’ya da Dalgacık Ağına uygulanan giriş vektörleri aynen uygulanmıştır. Dolayısı ile ÇKA için ayrıca bir öznitelik çıkartma evresi bulunmamaktadır. Ancak işaretin zaman penceresine ilave olarak girişe uygulanan RR aralığının bulunması işlemi bir anlamda öznitelik çıkarma evresi olarak kabul edilebilir.



Şekil 6.1 : Sistemin blok diyagramı.

6.1 Önışlemler

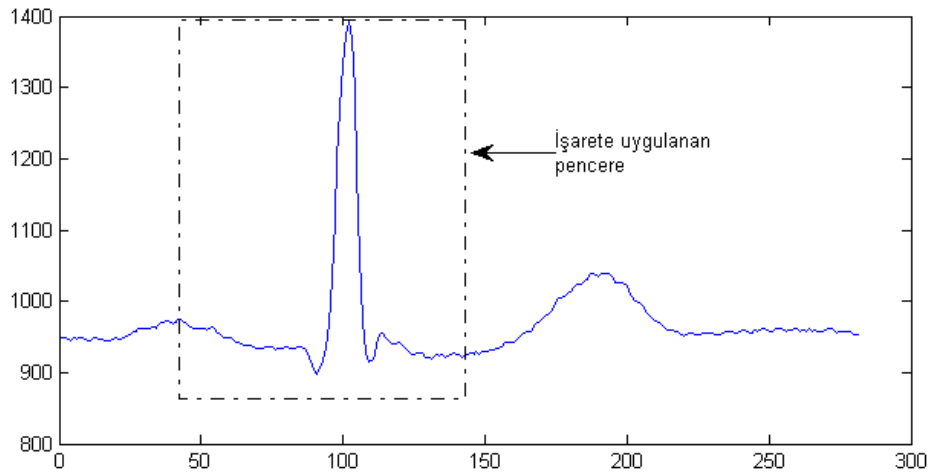
EKG işaretinde hastaların fizyolojisine, yaşına, cinsiyetine ve ölçüm sisteminin parametrelerine bağlı olarak R tepesinde kaymalar, genlik farkları ve gürültüler oluşabilmektedir. Bu etkiler işaretin sınıflanmasına olumsuz etkide bulunurlar. Şekil 6.2’de bu etkiler gösterilmiştir. Görüldüğü gibi işaretin taban hattında küçük te olsa kaymalar olmuş, iki vurunun R tepesi arasında da genlik farkları oluşmuştur. Sınıflama başarımının artırılması için bu etkileri ortadan kaldıracak bazı önışlemler uygulanması gerekmektedir. Tez kapsamında kullanıcı tarafından belirlenebilen bir hasta grubu için gerekli bütün önışlemleri yapan bir de MATLAB uygulaması geliştirilmiştir.



Şekil 6.2 : Önışlemlerden geçmemiş ardışık iki Normal EKG vurusu.

6.1.1 İşarete uygulanacak dikdörtgen pencerenin belirlenmesi

İşarete uygulanacak zaman penceresi belirlenirken sınıflama başarımına katkısı olmayacak veya olumsuz etkisi olacak bileşenleri dışarıda bırakacak minimum boyuttaki bir dikdörtgenin seçilmesi hedeflenmiştir. Bu hedef doğrultusunda olumsuz etkide bulunabilecek olan T-dalgasını dışarıda bırakacak şekilde R tepesi referans alınarak tek bir QRS kompleksini içeren dikdörtgen bir pencere oluşturulmuştur (Şekil 6.3). Dikdörtgen pencerenin boyutu ilk etapta kabaca 100 örnek olarak alınmış ancak daha sonra değişik boyutlardaki pencereler seçilerek bu seçimin isabeti doğrulanmıştır. R tepesinin pencere içerisindeki konumu farklı uzunluktaki pencereler için farklılık gösterebilmekle beraber aynı uzunluktaki pencereler için bütün örneklerde sabit alınmıştır.




Şekil 6.3 : İşarete uygulanan zaman penceresi.

6.1.2 Genlik ayarı


Dalgacık ağında uygulanan ana dalgacıkların yatay ekseninde $[-2,2]$ aralığı dışında kalan bileşenleri sıfıra yakınsar (Şekil 3.1). Özellikle aynı sınıfa ait vektörler arasında bu aralığı aşacak büyüklükte farklar olursa vektörler ana dalgacık ile çarpıldıktan sonra birçok bileşenini kaybeder. Bu durumda sınıflayıcı girişindeki bilgi miktarı çok düşer ve bu da sınıflama başarımını olumsuz etkiler. Genlik farklarını normalize ederek bu etkilerden kurtulmak için işaretin bütün bileşenleri veri tabanı içerisindeki olası en büyük genlik değerine bölünmüştür. Teorik genlik değerleri 0-2047 kapalı aralığında değişebilen işaretler pratikte 1500 genliğinin altında kalmaktadır. Bundan dolayı bütün genlikler 1500 değerine bölünerek genlik ayarlaması yapılmıştır.

6.1.3 Median ile taban hattı düzeltmesi


Sınıflama için kullanılan yöntem ne olursa olsun girişteki verinin yüksek bir başarımla sınıflanabilmesi için sınıflar arası mesafenin fazla, sınıf içi saçılımların ise düşük olması istenir. Şekil-6.4 ve Şekil 6.6'da sırasıyla Normal ve PVC vurusunun normalizasyon uygulanmamış dağılımları görülmektedir. Şekil 6.5 ve Şekil-6.7'de ise aynı tipteki verilerin normalizasyona uğramış dağılımları görülmektedir. Şekillerden görüldüğü gibi herhangi bir normalizasyona uğramamış EKG vurularının sınıflarası mesafesi düşük, sınıf içi saçılımları ise yüksektir. Taban hattındaki kaymalar, kazanç ve ofset farkları buna yol açmaktadır. Bazı testler bu düzeltme olmadan yapılarak ağların gürültü bağışıklığı kıyaslanmıştır. İşaretin taban hattındaki kaymanın önüne geçilebilmesi için *medyan filtre* yaklaşımı kullanılmıştır. Sıralanmış bir dizinin ortanca elemanına dizinin “medyan değeri” denilmektedir. Bir diziye bir pencere fonksiyonu uygulanması ve bu pencerenin medyan değerinin bulunmasına dayanan medyan filtre EKG işaretindeki keskin değişimlerin (R tepesi gibi) taban hattındaki kaymaya olan etkisini azaltmada standart ortalama alma işlemine göre daha iyi netice verdiği için tercih edilmiştir. Bulunan taban hattı işaretten çıkarılarak işaretin taban düzeltme işlemi yapılmıştır.




Şekil 6.4 : N virusunun sınıf içi saçılımı (Normalizasyon yok).



Şekil 6.5 : N virusunun sınıf içi saçılımı (Normalizasyon var).



Şekil 6.6 : V virusunun sınıf içi saçılımı (Normalizasyon yok).



Şekil 6.7 : V virusunun sınıf içi saçılımı (Normalizasyon var).

6.1.4 Önişlemler için geliştirilen MATLAB uygulaması

Önişlemlerde kullanılacak olan uygulama MATLAB 7.6 versiyonunda geliştirilmiştir. Uygulama kodları mümkün mertebe standart MATLAB fonksiyonlarından oluşturulmuştur. Dolayısıyla MATLAB'in alt sürümlerinde de değişiklik yapmaksızın veyahut az bir değişikliklikle çalıştırılabilir. Uygulamada ilk önce eğitim ve test kümesinde kullanılacak olan hastaların numaraları seilmektedir. Daha sonra seçilen hastalardaki aritmilerin türlerine göre her hastadan alınacak vuru sayısı belirlenmektedir. Normal vurusu bulunan hastalar için ilk önce dosya baştan sona taranarak ardışık dört Normal vuru bulunur. Ardışık dört tane bulunamazsa

bulunabildiği kadar ardışık Normal vuru bulunur. Ardışık vurular arasındaki ortalama RR aralığı bulunur. Bunun böyle yapılmasındaki neden, deneğin öncelikle Normal EKG vuruları veriyor olduğu varsayımından hareketle işaretlerin Normal vurlara göre normalizasyonudur. Daha sonra N,V,A,L,R sınıflarından birine ait olan vurular araştırılır. Bu vurular elde edilirken, birden fazla hastada bulunan vuru tipleri eşit sayıda her bir hastadan alınır. Seçilen diktörtgenin boyutuna göre işaret pencerelenir. Örneğin 100 boyutlu bir pencere için, vurunun R noktasından itibaren 61 örnek sola ve 38 örnek sağa gidilmek suretiyle QRS kompleksini içeren 100 boyutlu bir zaman penceresi elde edilir. Daha sonrada bir önceki vurunun R tepesi ile aradaki mesafe bulunur ve hastanın ortalama RR aralığının iki katına bölünerek normalize edilmiş bir RR aralığı elde edilir. Normal RR aralığının 2 katına bölünmesinin nedeni normalize değer (0,1) aralığında kalmasını sağlamaktır. Daha sonra işarete MATLAB'ın 'medfilt1' fonksiyonu uygulanır. Fonksiyonda filtre boyutu olarak 30 verilmiştir. Daha sonra elde edilen işaret 1500'e bölünerek genlik normalizasyonu yapılır. Her aritmiden kullanıcının belirlediği oranda artimi alındıktan sonra aritmiler '.mat' uzantılı eğitim ve test dosyalarına kaydedilir. Uygulanan çeşitli testlerde kimi önışlemler atlanmıştır. Bunlarla ilgili ayrıntılara tezin sonuçlar kısmında yer verilmiştir.

6.2 RR Aralığının Belirlenmesi

Dalgacık ağlarında tipik olarak işaretin kendisi ağın girişine uygulanır. EKG vurularında R tepesini merkez alıp QRS bölgesini içerisine alan dikdörtgenel bir pencere vurunun tipi hakkında hemen hemen tüm bilgiyi barındırır. Ancak bazı aritmi türlerinde QRS'in şeklinin yanı sıra RR aralığı da önemli bir anlam taşır. Bu amaçla *incelenen çalışmalarda bulunmayan ancak sınıflama başarımını artıracığı düşüncesiyle RR aralığı da dalgacık ağına giriş olarak verilmiş ve verilmediği duruma göre ortalama sınıflama başarı oranını %18 artırdığı görülmüştür*. Bu yapılan çalışmamızın önemini ortaya koymaktadır. Çok Katmanlı Ağın girişine kıyaslama yapılabilmesi için aynı giriş vektörleri uygulanmış ve RR ilavesinin sınıflama başarımına %9 artırdığı görülmüştür.

İşaretin 4 peşpeşe normalinin ortalama RR aralığı normal RR aralığı olarak kabul edilerek, her vurunun RR aralığının normal RR aralığının iki katına olan oranı tespit

edilir. Bazı testler bu parametre olmadan yapılarak bu parametrenin ağların başarımına olan katkısı araştırılmıştır.

6.3 Sınıflayıcı Olarak Dalgacık Ağı

Dalgacık Ağı uygulaması MATLAB 7.6 versiyonuyla geliştirilmiştir. Uygulama da mümkün mertebe MATLAB'ın standart fonksiyonları kullanılmıştır. Uygulamanın bu kısmında MATLAB hazır fonksiyonları (“ToolBox”) kullanılmamıştır. Uygulama üç evreden oluşmaktadır. Birinci evrede eğitim kümesindeki vektörlerden beşinci bölümde bahsedilen w^{WH} bellek elemanları ve saklı katman ile çıkış katmanı arasındaki w^{HS} dal ağırlıkları bulunur. w^{WH} bellek elemanları ağın Dalgacık Dönüşümü katmanındadır. Bu katmanda ana dalgacık olarak Morlet ve Meksika Şapkası kullanılmıştır. Ana dalgacık seçiminin sınıflama performansına olumlu/olumsuz önemli bir etkisinin olması beklenmemektedir. İkinci evrede bu parametreler eğitim kümesine uygulanarak optimum sigma parametreleri elde edilir. Eğitim kümesindeki düğüm sayısı çok fazla alınırsa bu evre eğitim süresini çok uzatır. Bu nedenle bir çok testte bu evre devre dışı bırakılmıştır. Zira sigma parametresi sonuçlar üzerinde çok büyük değişikliklere neden olmamaktadır. Son evrede ise test kümesinden alınan vektörler ağa uygulanarak sınıflama işlemi gerçekleştirilmektedir.

6.4 Sınıflayıcı Olarak Çok Katmanlı Ağ

Yapay sinir ağlarında çok çeşitli ağ yapıları ve modelleri vardır. En çok kullanılan ağ yapılarından birisi üçüncü bölümde anlatılan ÇKA'dir. Bu ağda bilginin akışı ileri yönlüdür. Öğrenme ve eğitime algoritması olarak genelde türeve dayalı geriye yayılım (“back propagation”, GY) algoritmaları tercih edilir. Çalışmada dalgacık ağlarıyla karşılaştırmak için ÇKA kullanılmasının nedeni kolay uygulanabilirliği ve yaygınlığından dolayıdır. Böylece dalgacık ağlarının çalışması hakkında daha kolay fikir sahibi olunabilir.

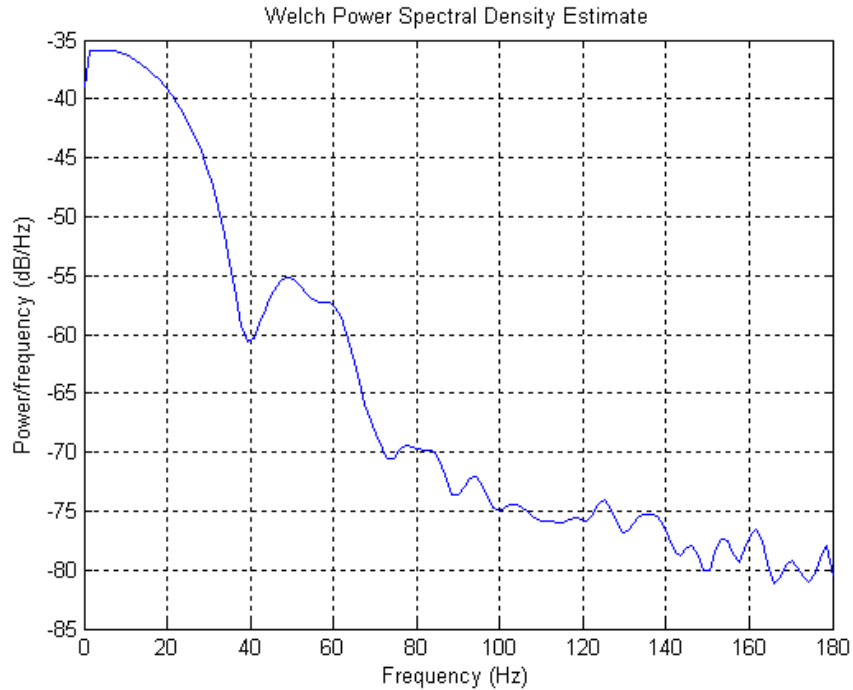
Çok katmanlı ağ olarak MATLAB'in ‘ntraintool’ aracı kullanılmıştır. Bu araç hata fonksiyonu olarak en küçük kareler yöntemini (mse), eğitim algoritması olarakta Levenberg-Marquard'ı (trainlm) kullanmaktadır.

6.5 Uygulamanın Giriş Verisi ve MIT-BIH Veritabanı

Uygulamada kullanılan veriler MIT-BIH veri tabanından alınmıştır. MIT-BIH (Massachusetts Institute of technology-Beth Israel Hospital) veri tabanında bulunan EKG kayıtları, Beth-Israel Hospital Aritmi Laboratuvarı tarafından 1975-1979 yılları arasında alınmış olan 4000'i aşkın uzun-dönem Holter kayıtlarından oluşturulmuş bir kümedir(Url-1). Bu veri tabanında 48 adet EKG kaydı olup bu kayıtların herbiri 30 dakika uzunluktadır.

EKG kayıtları yaşları 32-89 arasında değişen 25 erkek ve 23-89 yaşları arasındaki 22 kadından alınmıştır. Hastaların tümüne iki farklı derivasyon uygulanmıştır. Kayıtların birçoğunda derivasyonlardan biri II nolu standart bipolar derivasyondur. Diğeri ise çoğunlukla V_1 , zaman zaman V_2 veya V_5 , kayıtların birinde de V_4 derivasyonudur. Normal QRS kompleksleri genellikle II nolu standart bipolar derivasyonla alınan işarette belirgindir.

İşaret 360 Hz ile örneklenmiştir. Ancak, yapılan frekans spektrumu analizinde (Şekil-6.4) görüldüğü üzere Elektrokardiyogram işaretlerinin 90 Hz.'in üzerindeki frekanslardaki gücünün çok az olduğu görülmüştür.



Şekil 6.8 : Elektrokardiyogram işaretinin güç spektrumu (360 Hz ile örneklenmiş).

İşaretler -5 mV , +5mV bölgesinde 11-bit çözünürlüğe sahiptir. Örnek değerleri 0-2047 kapalı aralığında değerler almakta ve 1024 değeri 0 V'a karşılık gelmektedir.

Sınıflanacak veriler farklı iki hasta grubundan alınmak suretiyle hastanın yaşı, cinsiyeti vs. özel durumlarının sonuca olan etkisi en aza indirilmiştir. Tez boyunca yapılan ayrıntılı testler genelde birinci hasta grubu üzerinden yapılmıştır. Bu hastalar MIT-BIH veri tabanındaki 106, 109, 209 ve 212 nolu hastalardır. Grupta Normal vurusu (N) bulunan üç hastadan yedişer örnek alınarak toplam 21 normal kategorisi oluşturulmuştur. Diğer hastalardan barındırdıkları aritmi tipinden 21 kategori seçilmiştir. Diğer aritmi tipleri; erken karıncık kasılması (V), erken kulakçık atımı (A), sol dal blok vurusu (L) ve sağ dal blok vurusudur (R). Birinci hasta grubuyla karşılaştırmak maksadıyla tamamen farklı hastalardan oluşturulan ikinci hasta grubu da 103, 119, 124, 200, 214 ve 232 nolu hastalardır. Bu hastalardan aritmiler alınırken yine birinci grubun seçiminde kullanılan mantık kullanılmış ve Normal vurusunun (N) yanı sıra belli bir aritmiyi barındıran hastalardan eşit sayılarda vurular alınmıştır. N vurusu üç farklı hastadan, V vurusu iki farklı hastadan ve A vurusu da yine iki farklı hastadan alınmıştır. Bu farklılığı formüle edebilmek için kategori sayısı hem ikiye hem üçe bölünen 24 sayısına çıkarılmıştır. Test kümesinde her vurudan 120'şer tane alınmak suretiyle toplam 600 veri üzerinde sonuçlar incelenmiştir.

7. SONUÇLAR VE DEĞERLENDİRME

Yapılan çalışma dört ana başlık altında özetlenebilir. 1) Ön işlemlerin sınıflama performansına katkısının incelenmesi. 2) Giriş vektörü boyutlarının ve pozisyonlarının sınıflama performansını en üst seviyeye çıkaracak şekilde seçilmesi. 3) İşaretin sadece zaman domeni parametrelerinden oluşan giriş vektörlerine R-R aralığının ilave edilmesiyle sınıflama başarımının artırılması. 4) İstatistik Dalgacık Ağı ve Çok Katmanlı Ağın sınıflama performansının değişik boyutlardaki giriş vektörleri ile kıyaslanması.

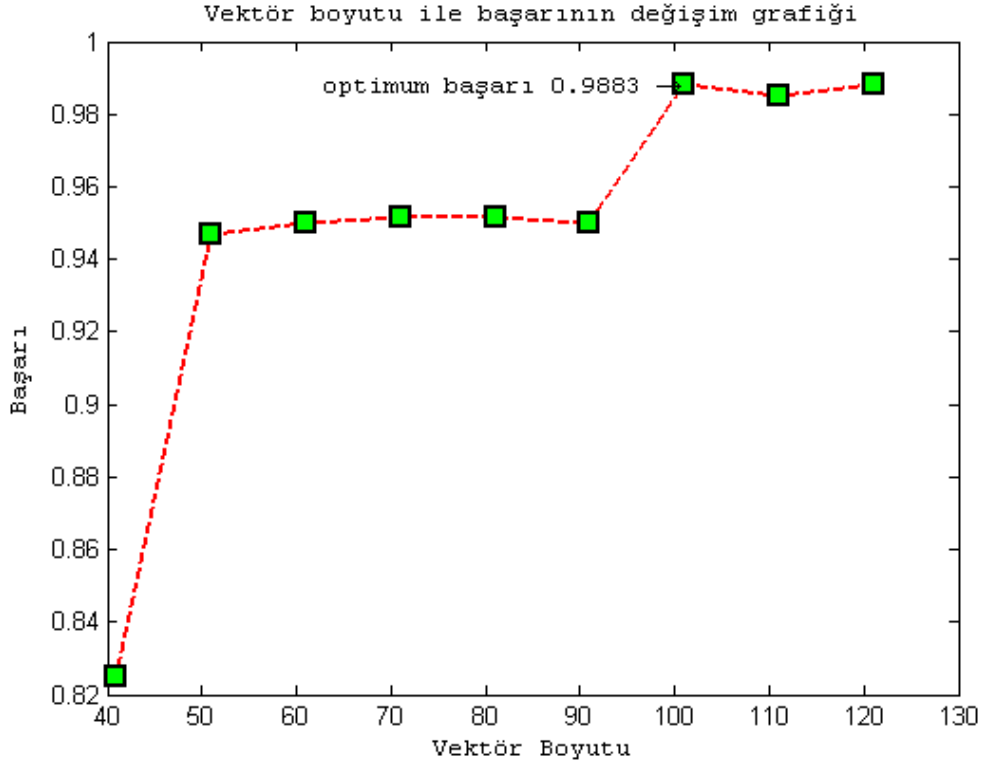
Uygulama kapsamında öncelikle her sınıftan 21 örnekle eğitim kümesi oluşturulmuştur. Normal vurusu üç farklı sınıftan toplandığı için her hasta için alınan değerlerin ortalaması birer giriş vektörü olarak ağa verilmiştir. Daha sonra diğer sınıfların vuruları incelenerek sınıf içi saçılımın sınırlarındaki vurulardan toplamda 14 vektörlük eğitim kümesi ile testler yapılmıştır. Bu şekilde ağın az sayıda giriş vektörüyle ne kadar yüksek bir başarımler elde edebileceğinin cevabı araştırılmıştır. Daha sonrada sınıf içi saçılıma bakmaksızın eğitim kümesindeki 21 vurunun her biri ayrı ayrı eğitim kümesine sokulmak suretiyle toplam 105 vektörle aşağıda detaylarıyla bahsedilen çeşitli testler yapılmış ve bunların sonuçları ÇKA'nın sonuçlarıyla karşılaştırılmıştır.

Yapılan analizler gerek İstatistiksel Dalgacık Ağının gerekse Çok Katmanlı Ağın sınıflama performansının genlik değişimlerinden ve işaretin taban hattı kaymasından etkilendiğini göstermektedir. Çizelge 7.1'de bu etkiden kurtulmak için uygulanan medyan filtrenin başarıma olan katkısı açıkça görülmektedir.

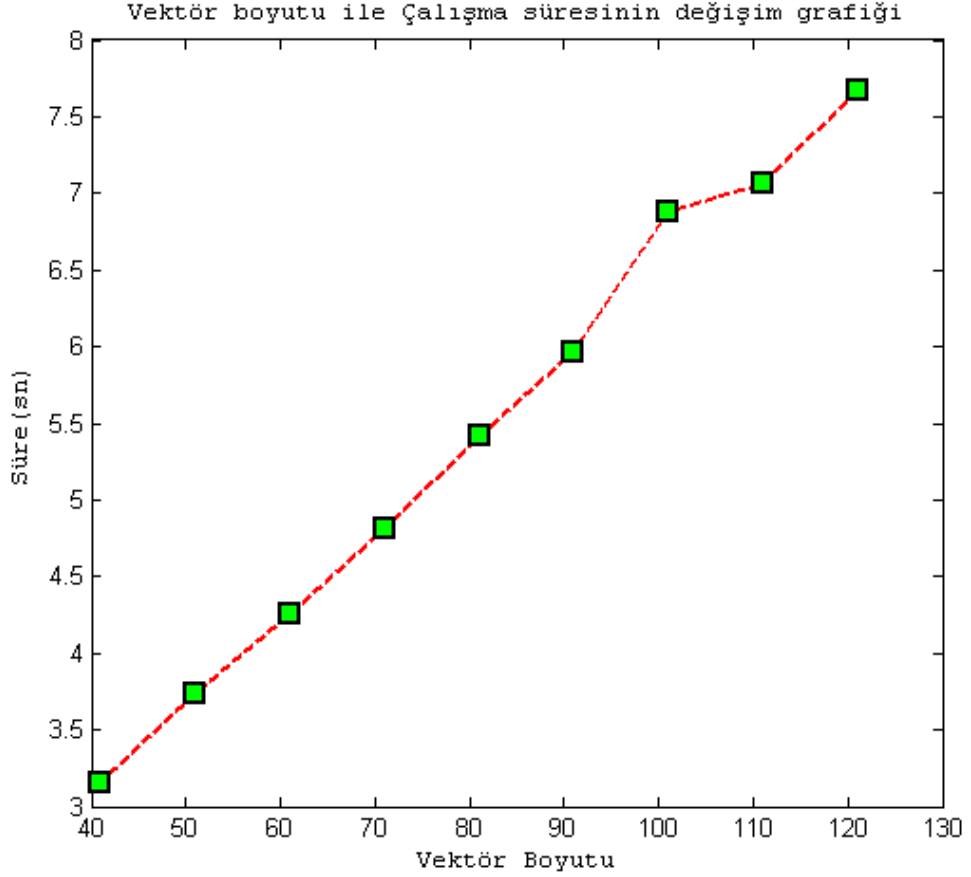
Çizelge 7.1 : Median filtrenin başarıma etkisi.

Sınıflar	Dalgacık		YSA	
	Filtre var	Filtre yok	Filtre var	Filtre yok
N tipi vuru	116/120	100/120	120/120	85/120
V tipi vuru	119/120	111/120	120/120	118/120
A tipi vuru	118/120	117/120	118/120	119/120
L tipi vuru	120/120	120/120	120/120	120/120
R tipi vuru	120/120	111/120	120/120	120/120
Genel başarıım	0.9883	0.9317	0.9967	0.9367

Giriş vektörlerinin boyutlarının da hem İstatistiksel Dalgacık Ağının hem de Çok Katmanlı Ağın sınıflama performansı üzerinde belirgin bir etkisi olduğu görülmüştür. İstatistiksel Dalgacık Ağında boyut etkisi kuşkuyla yer bırakmayacak derecede nettir. Şekil 7.1’de görüldüğü gibi R -61 ile R+39 noktaları arasını kapsayan 100 boyutlu dikdörtgen pencere en iyi performansı vermektedir. Daha büyük pencereler, T dalgasına doğru değilde sola doğru büyütülerek elde edilirse sınıflama performansında bir değişime neden olmamaktadır. T dalgasına doğru olan büyütme performansını azaltmaktadır. Şekil 7.2’de görüleceği üzere İstatistiksel Dalgacık Ağında eğitim+çalışma süresi ile vektör boyutu arasında doğrusal artan bir ilişki vardır. Çok Katmanlı Ağ’da da bahsi geçen 100 boyutlu pencere en yüksek performansı vermektedir. Ancak Şekil 7.3’te de görüldüğü gibi pencere boyutunun düşmesiyle sınıflama performansının azalması arasında devamlı azalan bir ilişki yoktur. Ağın kararsız yapısından dolayı daha düşük boyutlu pencerelerde daha yüksek başarımlara ulaşmak bazen mümkün olmaktadır.

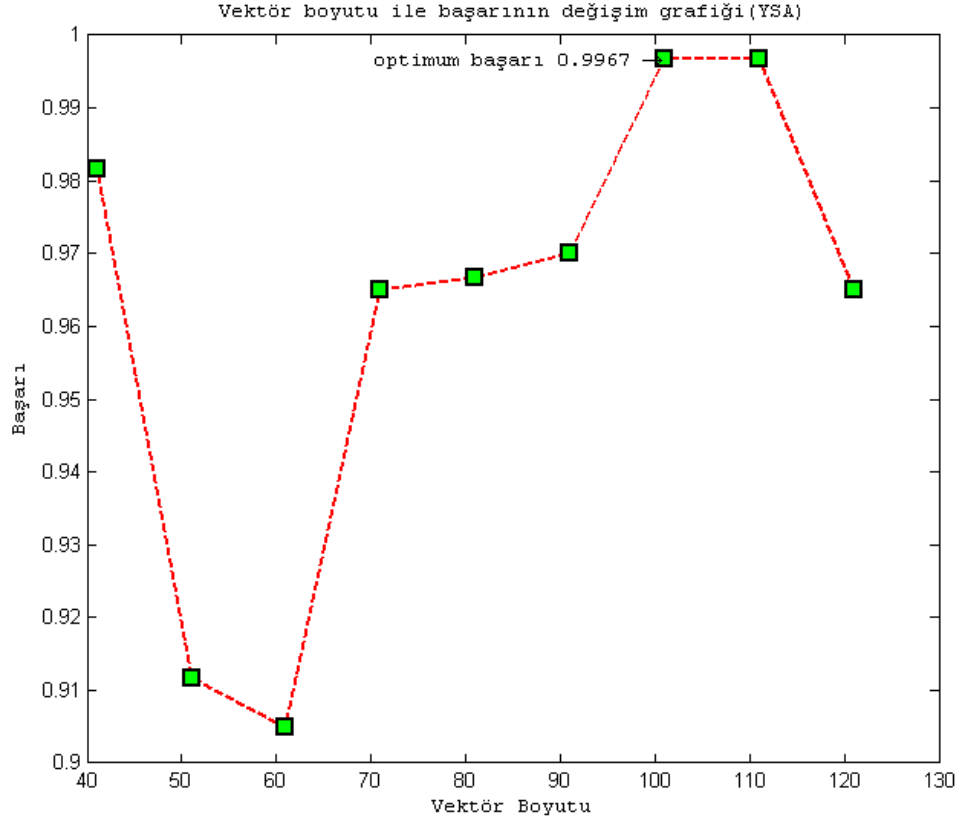


Şekil 7.1 : İstatistiksel Dalgacık Ağında giriş vektörü boyutu - ağ başarı oranı değişimi.



Şekil 7.2 : Dalgacık ağı çalışma süresi (eğitim+test) süresinin giriş vektörü boyutuna göre değişimi.

EKG işaretinin 90 Hz.'in üzerinde önemli sayılabilecek bir bileşene sahip olmadığından hareketle, seçilen dikdörtgen pencerenin uzunluğunu değiştirmeden, sadece örnekleme aralığını arttırmak suretiyle (downsampling) giriş vektör boyutunun düşürülmesinin sınıflama performansına önemli sayılabilecek ölçüde menfi bir etkisinin olmadığı görülmüştür. Böylece her iki ağın eğitim ve test süresinin düşürülmesi mümkün olabilmektedir. Çizelge 7.3'te zaman penceresinin boyu sabit kalmak kaydıyla örnekleme aralığı iki katına çıkarılarak yapılmış sınıflamaların başarımı görülmektedir.



Şekil 7.3 : Çok Katmanlı Ağda giriş vektör boyutu - ağ başarı oranı değişimi

Çizelge 7. 2 : Genlik ayarının başarıma etkisi.

Sınıflar	Dalgacık		YSA	
	Genlik ayarı var	Genlik ayarı yok	Filtre var	Filtre yok
N tipi vuru	116/120	120/120	120/120	104/120
V tipi vuru	119/120	20/120	120/120	94/120
A tipi vuru	118/120	20/120	118/120	75/120
L tipi vuru	120/120	21/120	120/120	105/120
R tipi vuru	120/120	21/120	120/120	117/120
Genel başarı	0.9883	0.3367	0.9967	0.8250

Çizelge 7.3 : İndirgenmiş giriş vektörü ile ağ başarımları. Boyut 51+ RR oranı parametresi.

(Not: YSA ağında verilen süre 600 iterasyon için geçen süredir. Dalgacık ağında verilen süre ağın eğitim ve testi için geçen sürenin toplamıdır. Her iki ağ için verilen süreler birbirleri ile kıyaslanmamalıdır, ancak aynı ağın farklı giriş vektörleri ile eğitilmesinden kaynaklanan farklar anlamlıdır).

Sınıflar	Dalgacık		YSA	
	Boyut 101	Boyut 52	Boyut 101	Boyut 52
N tipi vuru	116/120	116/120	120/120	120/120
V tipi vuru	119/120	117/120	120/120	120/120
A tipi vuru	118/120	117/120	118/120	117/120
L tipi vuru	120/120	117/120	120/120	114/120
R tipi vuru	120/120	120/120	120/120	120/120
Genel başarımlar	0.9883	0.9833	0.9967	0.9850
Başarımlar farkı	-	-%0.51	-	-%1.17
Çalışma Süresi*(sn)	6.8	3.94	90	35
Çalışma Süresi Farkı	-	-%42.06	-	-%61

Çalışma boyunca yapılan testler elektrokardiyogram işaretlerinin sınıflanmasında sadece işaretin QRS bölgesindeki genliğe dayalı sınıflamanın yeterli olmadığını göstermektedir. Hadd-i zatında bu şekilde bir sınıflamaya gitmek doğru da değildir. Zira bazı aritmiler tanımlanırken, bazı hastalıklar teşhis edilirken RR aralığı bir ölçü olarak alınmaktadır. Hastaların kalp atış hızlarının, yaşa, cinsiyete ve hastanın o anki aktivitesine göre değişmesinden dolayı RR aralığının yalın halde bir parametre olarak ağa verilmesi başarımları düşürecektir. RR aralığı ardışık 4 normal RR aralığının ortalama değerinin iki katına bölünmek suretiyle bu tür faktörlerin etkisi yok edilmiştir. Çizelge 7.4'te RR aralığının ağ başarımlarına olan katkısı açık bir şekilde görülmektedir.

Çizelge 7.4 : RR oranının ağ başarımlarına olan katkısı.

Sınıflar	Dalgacık		YSA	
	RR oranı var	RR oranı yok	RR oranı var	RR oranı yok
N tipi vuru	116/120	105/120	120/120	112/120
V tipi vuru	119/120	79/120	120/120	117/120
A tipi vuru	118/120	78/120	118/120	81/120
L tipi vuru	120/120	120/120	120/120	118/120
R tipi vuru	120/120	120/120	120/120	118/120
Genel başarımlar	0.9883	0.8367	0.9967	0.91
İyileştirme	+ %18.12		+ %9.53	-

Çizelge 7.5 : Eğitim kümesindeki vektör sayısının başarımlar ve çalışma süresi üzerindeki etkisi.

Sınıflar	Dalgacık	
	105 öbek	14 öbek
N tipi vuru	116/120	114/120
V tipi vuru	119/120	119/120
A tipi vuru	118/120	116/120
L tipi vuru	120/120	120/120
R tipi vuru	120/120	113/120
Genel başarımlar	0.9883	0.9700
Çalışma Süresi(sn)	6.8	1.25

Çalışma kapsamında eğitim kümesine alınacak vektör sayısının nasıl düşürülebileceği konusu araştırılmıştır. Sınıflama işleminin gerçekleştirildiği katman İstatistiksel Yapay Sinir Ağı (İYSA, “ Probabilistic Neural Network”, PNN) ağından oluşmaktadır. Bu yapay sinir ağı uygulaması farklı olmakla beraber temelde k-En Yakın Komşu ağına benzemektedir. Farkı en yakın k tane komşuyu değil bütün sınıflara olan komşuluğu esas almasıdır. Dolayısıyla İYSA çok sayıda düğüm ile eğitilirse ÇKA'ya göre daha yavaş çalışır. Hızlı çalışması isteniyorsa etkisiz düğümler ağdan kaldırılmalıdır. Çalışmada bu amaçla sınıflara ait bütün düğümler yerine düğüm ortalamalarının kullanılması da test edilmiştir. Çizelge 7.5'te her aritminin ortalama vektörü ve sınıf dağılımlarının belirgin bir öbekleşme gösterdiği

bölgelerden vektörler alınmak suretiyle elde edilmiş toplam 14 öbektan oluřan eđitim kümesinin sınıflama bařarımına ve alıřma süresine olan etkisi gösterilmiřtir.

Yapılan testlerde ok Katmanlı Alma'ın (KA, YSA) her alıřtırıldıđında farklı farklı sonular üretebildiđi ve kararsız bir yapıya sahip olduđu görülmüřtür. Giriř vektörlerindeki sınıflama bařarımına olan etkisinin ortaya ıkması için, yapılan her test YSA için 10 defa tekrar edilmiřtir. Bu denemelerden en yüksek bařarımı verenin sınıflama sonucu izelge 7.1, izelge 7.2, izelge 7.3, izelge 7.4 ve izelge 7.5'te YSA sonucu olarak verilmiřtir.

izelge 7.6 : Dalgacık Ađı ortalama sınıflama bařarım matrisi.

Gerek Sınıf \ Sınıflanan	N	P	A	L	R	Toplam
N	116	-	4	-	-	120
V	1	119	-	-	-	120
A	2	-	118	-	-	120
L	-	-	-	120	-	120
R	-	-	-	-	120	120

Dalgacık Ađı ve YSA'nın sınıflama bařarımlarını kıyaslamak için her iki ađın giriřine, en yüksek bařarımı veren 100 boyutlu (RR aralıđı ilave edilmiř ve normalizasyon yapılmıř olarak) giriř vektörleri uygulanmıřtır. İki ađın kıyaslanması söz konusu olunca YSA için yapılan 10 denemenin ortalamasının alınması daha adil olacađı düşünölmüřtür. Bu kořullarda yapılan 10 denemenin sonucunda YSA ortalama sınıflama bařarımı %93.95, Dalgacık Ađınının sınıflama bařarımı ise %98.83'tür. izelge 7.6'da Dalgacık Ađının ortalama sınıflama bařarım matrisi, izelge 7.7'de ise YSA'nın ortalama sınıflama bařarım matrisi verilmiřtir.

Çizelge 7.7 : YSA ortalama sınıflama başarımları matrisi.

Gerçek Sınıf \ Sınıflanan	N	P	A	L	R	Toplam
N	114.6	0.1	2.7	0.4	2.2	120
V	4.3	110.7	0.5	4.4	0.1	120
A	14	0.8	101.1	0.1	4	120
L	2	-	-	118	-	120
R	-	-	0.7	-	119.3	120

Hasta kişiye hasta teşhisi konması: TP (“true positive”), sağlam kişiye sağlam teşhisi konması: TN (“true negative”), sağlam kişiye hasta teşhisi konması: FP (“false positive”) ve hasta kişiye sağlam teşhisi konması FN (“false negative”) olmak üzere (7.1) ve (7.2) eşitlikleri kullanılarak ‘Dalgacık Ağı ve YSA’nın Normal sınıfı için ‘ortalama duyarlılığı’ (“Sensitivity”) ve ‘ortalama özgüllüğü’ (“Specificity”) ayrıca hesaplanmıştır. Bu sonuçlar özet halinde Çizelge 7.7’de verilmiştir.

$$\text{Belirlilik} = \frac{TN}{TN+FP} \quad (7.1)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (7.2)$$

Çizelge 7.8 : Normal sınıfı için ortalama duyarlılık ve belirlilik oranları

	Dalgacık	YSA
Ortalama Duyarlılık (“Sensitivity”)	0.9666	0.9550
Ortalama Belirlilik (“Specificity”)	0.9937	0.9577

Sonuç olarak İstatistiksel Sinir Ağlarından (PNN, GRNN) biri olan İstatistiksel Dalgacık Ağı ile Çok Katmanlı Ağ (ÇKA) arasında aşağıdaki farklardan bahsetmek mümkündür:

- PNN/GRNN ađları KA'ya gre daha hızlı eđitilebilir.
- PNN/GRNN ađları KA'ya gre daha dođru sınıflama sonuları retir.
- PNN/GRNN ađları KA'ya gre daha kararlıdır. KA'nın eđitim sresi dđm katsayılarına verilen ilk deđerlere ok bađlıdır ve ođunlukla hata fonksiyonun yerel minimumlarına yakınsarlar.
- PNN/GRNN ađları dzensiz dađılmıř giriř vektrlerine greceli olarak daha duyarsızdırlar.
- PNN/GRNN yeni durumları sınıflamada KA'ya gre daha yavařtır.
- PNN/GRNN ađlarının alıřırken daha ok belleđe ihtiya duyarlar. (Url – 2)

İstatistiksel Sınır Ađları'nın en temel sorunu alıřırken fazla belleđe ihtiya duymalarıdır (Specht, 1988). Ancak gemiř yıllarda problem olan bu durum bilgisayar tekneolojisindeki geliřmelerle beraber nemini kaybetmiřtir. Gnmzde bellek elemanlarının kapasitesi gemiř 20 yıla gre katlanarak artmıřtır. Bylece İstatistiksel Sınır Ađları koalylıkla uygulanabilir hale gelmiřtir.

KAYNAKLAR

- Bolat, B.**, 2005. Kamışlı Enstrüman Seslerinin İstatistiksel Sinir Aları ile Tanınması, *Sigma Mühendislik ve Fen Bilimleri Dergisi*, **2**, 36-42.
- Dokur, Z.**, 1999. Yapay sinir ağları ve genetik algoritmalar kullanılarak EKG vurularının sınıflandırılması, *Doktora Tezi*, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Foo, S.Y. Stuart, G. Harvey, B. Meyer-Baese** 2002. ANN Based ECG Pattern Recognition. *Eng. Appl. Artif. Intell.*, **15**, 253–260.
- Hecht-Nielsen, R.**, 1990. Neurocomputing, HNC, Inc. and University of California, San Diego, Addison-Wesley.
- Korürek, M.**, 1996. Tıp Elektronikğinde Tasarım İlkeleri, İ.T.Ü. Elektrik-Elektronik Fakültesi Ofset Baskı Atölyesi, İstanbul.
- Lecutai, G.**, 1997. Adaptive self-tuning neural wavelet network controllers, *Doctora of philosophy dissertation*, Faculty of the Virginia Polytechnic, The Electrical Engineering Department, Virginia.
- Lin, C., and Du, Chen, T.**, 2008. Adaptive wavelet network for multiple cardiac arrhythmias recognition. *Expert Systems with Applications* **34**, 2601–2611.
- Lin, C.J.**, 1997. Nonlinear systems control using self-constructing wavelet Networks, *Applied Soft Computing*, **9**, 71–79.
- Masters, T. and Land, W.** 1997. A new training algorithm for the general regression neural network, *IEEE international conference on computational cybernetics and simulation*, October.1997, **3**, 1990–1994.
- Nizam, A.**, 2008. Karınca koloni optimizasyonuna dayalı yeni bir aritmi sınıflama tekniği, *Doktora Tezi*, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Parzen, E.**, 1962. On Estimation of a Probability Density Function and Mode, *Annals of Mathematical Statistics*, **33**, 1065-1076.
- Palreddy, S. Hu, Y.H. Mani, V. Tompkins, W.J.**, 1997. A multiple-classifier architecture for ECG beat classification, *Neural Networks for Signal Processing VII. Proceedings of IEEE Workshop*, 172-181.
- Postalcioglu, S. and Erkan, K. and Bolat, E.D.**, 2005. Comparision of wavenet and neural net in system, *KES 2005*, Melbourne, Australia, April 14-16.
- Rumelhart, D.E. Hinton, G. E. Williams, R. J.**, 1986. Learning internal representations by error propagation, *Nature*, **323**, 533-536.
- Specht, D. F.**, 1988. Probabilistic neural network for classification mapping, or associative memory. *IEEE Int. Conf. on Neural Networks*, **1**, 525-532.

Zhang, Q., Benveniste, A., 1992. Wavelet Networks. *IEEE Transaction on Neural Networks*, **3**, 889-898.

Zhang, Y., Xie, Y., 2006. A wavelet network model for short-term traffic volume forecasting, *Journal of Intelligent Transportation Systems*, **10**, 141–150.

Url-1 <<http://www.physionet.org/physiobank/>>, alındığı tarih 29.09.2008.

Url-2 < <http://www.dtrek.com/pnn.htm>>, alındığı tarih 25.05.2009.

ÖZGEÇMİŞ

Ad Soyad: Abdullah Karadağ
Doğum Yeri ve Tarihi: Palu, 1981
Adres: Başakşehir 4. Etap Mah. 1. Kısım B-43 D:36
Esenler/İSTANBUL
Lisans Üniversite: İstanbul Teknik Üniversitesi Elektronik ve Hab. Müh.