

**KARDİYAK DOPPLER İŞARETLERİNİN YAPAY SINIR AĞI VE
NEFCLASS İLE SINIFLANDIRILMASI**

Necaattin BARIŞCI

**DOKTORA TEZİ
ELEKTRONİK VE BİLGİSAYAR EĞİTİMİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

KASIM 2005

ANKARA

Necaattin BARIŐCI tarafından hazırlanan KARDİYAK DOPPLER İŐARETLERİNİN YAPAY SİNİR AĐI ve NEFCLASS İLE SINIFLANDIRILMASI adlı bu tezin Doktora tezi olarak uygun olduĐunu onaylarım.

Prof. Dr. İnan GÜLER Yrd. DoĐ. Dr. Fırat HARDALAÇ
Tez Yöneticileri

Bu alıŐma, jürimiz tarafından Elektronik ve Bilgisayar EĐitimi Anabilim Dalında Doktora tezi olarak kabul edilmiŐtir.

Başkan: : Prof. Dr. etin ELMAS

Üye : Prof. Dr. Ömer Faruk BAY

Üye : Prof. Dr. Ahmet ARSLAN

Üye : Prof. Dr. İnan GÜLER

Üye : Yrd. DoĐ. Dr. Fatih ELEBİ

Bu tez, Gazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygundur.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iii
ABSTRACT.....	v
TEŞEKKÜR.....	vii
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ.....	ix
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. KARDİYAK DOPPLER İŞARETLERİ, YAPAY SİNİR AĞLARI ve SİNİRSEL BULANIK SINIFLAYICILAR.....	4
2.1. Kalbin Çalışması ve Kan Akış Hızı.....	4
2.2. Ultrasonik Doppler Prensipleri.....	8
2.3. Kardiyak Doppler İşaretlerinin Hızlı Fourier Dönüşümü ile Analizi.....	11
2.3.1. Kardiyak Doppler işaretlerinin kaydedilmesi ve analizi.....	13
2.3.2. Kardiyak Doppler işaretlerine uygulanan HFD algoritması.....	15
2.4. Yapay Sinir Ağları.....	19
2.4.1. Çok katmanlı algılayıcılar ve öğrenme algoritmaları.....	20
2.4.2. Kardiyak Doppler işaretlerinin çok katmanlı algılayıcı sinir ağına uygulanması.....	25
2.4.3. Yapay sinir ağının performansının değerlendirilmesi.....	27
2.5. Sinirsel Bulanık Sınıflayıcılar.....	29
2.5.1. NEFCLASS modelin yapısı.....	31
2.5.2. Kural tabanının öğrenme algoritması.....	33
2.5.3. Bulanık kümelerin eğitimi algoritması.....	37
2.5.4. Kural tabanının budanması.....	40

2.6. Kardiyak Doppler parametrelerinin NEFCLASS ile sınıflandırılması.....	41
3. BULGULAR ve İRDELEME.....	46
3.1. Aort Kapakçığında Kaydedilen Kardiyak Doppler İşaretlerinin HFD Analizi Bulguları.....	46
3.2. Mitral Kapakçıktan Kaydedilen Kardiyak Doppler İşaretlerinin Güç Spektrum Yoğunluğu Analizleri.....	50
3.3. Kardiyak Doppler İşaretlerinin Çok Katmanlı Algılayıcı Sinir Ağı ile Sınıflandırılması.....	53
3.4. Kardiyak Doppler İşaretlerinin NEFCLASS ile Sınıflandırılması.....	56
3.5. İrdeleme.....	64
4. SONUÇ.....	67
KAYNAKLAR.....	69
ÖZGEÇMİŞ.....	74

TEŐEKKÜR

Çalıőmalarım boyunca ilgi ve bilimsel katkılarıyla beni yönlendiren tez danışmanlarım Prof. Dr. İnan GÜLER ve Yrd. Doç. Dr. Fırat HARDALAÇ'a, ayrıca çalışmalarımda bana destek veren arkadaşım Dr. Uçman ERGÜN'e teşekkürlerimi sunarım.

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Hastalıklara ait istatistiksel değerler	47
Çizelge 3.2. Test sonuçlarının sınıflama tablosu	55
Çizelge 3.3. Test performans sonuçları.....	55
Çizelge 3.4. İstatistiksel sonuçlar	56
Çizelge 3.5. 500 adımdaki kurallar (Aort kapakçığı).....	60
Çizelge 3.6. Sinirsel bulanık sınıflamaya ait değerler (Aort kapakçığı)	60
Çizelge 3.7. 500 adımda budamadan sonraki kurallar (Aort kapakçığı).....	60
Çizelge 3.8. Sinirsel bulanık sınıflamaya ait değerler (Budamadan sonra, Aort).....	61
Çizelge 3.9. 1000 adımdaki kurallar (Mitral kapakçık)	62
Çizelge 3.10. Sinirsel bulanık sınıflamaya ait değerler (Mitral kapakçık)	63
Çizelge 3.11. 1000 adımda budamadan sonraki kurallar (Mitral kapakçık)	63
Çizelge 3.12. Sinirsel bulanık sınıflamaya ait değerler (Budamadan sonra, Mitral)..	63

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Kalbin yapısı	5
Şekil 2.2. Kan akış hızı ve basınç ilişkisi. a)Düzgün ve türbülanslı akıştaki hız b)Normal ve engellenmiş arterdeki akış hızı.....	7
Şekil 2.3. Frekansın damara gönderilmesi ve yansıyan dalgalar.....	11
Şekil 2.4. Ölçüm sisteminin blok diyagramı.....	13
Şekil 2.5. Örneklenmiş Doppler sinyalinin çerçeveler halinde gruplanması.....	14
Şekil 2.6. Doppler kan akış hızı dalgaşekli ve çok kullanılan üç indisi: S, sistolik tepe, D, diastolik vadi ve O, ortalama kan akış hızı.....	15
Şekil 2.7. Doppler sinyallerine uygulanan HFD algoritması.....	16
Şekil 2.8. HFD sonogramlarına örnekler a) Sağlıklı b) Yetmezlik c) Darlık.....	17
Şekil 2.9. Geri yayılım çok katmanlı algılayıcı yapısı.....	20
Şekil 2.10. Çok katmanlı bir algılayıcı geri yayılım akış şeması.....	24
Şekil 2.11. NEFCLASS modelin yapısı.....	32
Şekil 2.12. Kural öğrenmeden sonraki sınıflama.....	36
Şekil 2.13. Bulanık kümelerin değiştirilmesi.....	38
Şekil 2.14. Bulanık küme öğrenmesinden sonraki sınıflama.....	39
Şekil 2.15. Klasik kümelerin bulanık küme haline getirilmesi.....	41
Şekil 2.16. Maximum ve minimum operatörleriyle bulanık kural tabanı ve değerlendirilmesi.....	44
Şekil 3.1. 55 yaşında sağlıklı kişiye ait spektral eğri (kişi no: 5).....	48
Şekil 3.2. 58 yaşında sağlıklı kişiye ait spektral eğri (kişi no: 17).....	48
Şekil 3.3. 60 yaşında aort yetmezliği olan kişiye ait spektral eğri (kişi no: 26).....	48
Şekil 3.4. 63 yaşında aort yetmezliği olan kişiye ait spektral eğri (kişi no: 33).....	49

Şekil 3.5. 57 yaşında aort darlığı olan kişiye ait spektral eğri (kişi no: 45).....	49
Şekil 3.6. 62 yaşında aort darlığı olan kişiye ait spektral eğri (kişi no: 52).....	49
Şekil 3.7. 59 yaşında sağlıklı kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 7)50	
Şekil 3.8. 62 yaşında sağlıklı kişiye ait güç spektrum yoğunluğu eğrisi(kişi no:12)51	
Şekil 3.9. 60 yaşında mitral yetmezliği olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 28).....	51
Şekil 3.10. 65 yaşında mitral yetmezliği olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 35).....	52
Şekil 3.11. 58 yaşında mitral darlığı olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 48).....	52
Şekil 3.12. 61 yaşında mitral darlığı olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 56).....	53
Şekil 3.13. Bulanık kümeler (Aort kapakçığı).....	57
Şekil 3.14. Bulanık kümeler (Mitral kapakçık).....	58

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
f_d	Doppler fark frekansı
f_t	Gönderilen dalga frekansı
f_r	Alınan frekans
v	Kandaki parçacıkların hızı
c	Ultrasonik dalğanın ortamdaki hızı
θ	Ultrasonik dalga ile hedefin akış yönü arasındaki açı
X_k	Ayrık Fourier katsayıları
N	Çerçeve boyu
$x(n)$	Zaman domeni giriş işareti
$P(k)$	Spektral güç yoğunluğu
x_i	Giriş değişkeni
w_{ij}	Bağlantı ağırlıkları
y	Fiili çıktı
f	Eşik fonksiyonu
θ_i	Eşik değeri
δ	Tek bir çıktı düğümünün hatası
η	Öğrenme katsayısı
α	Momentum katsayısı
r	Korelasyon katsayısı
μ	Bulanık kümenin üyelik derecesi
R_k	Bulanık kurallar
$A_{J_n}^{(n)}$	Bulanık dilsel terimler
C_J	Sinirsel bulanık sistemde sonuç kümesi
L	Öğrenme kümesi

Kısaltmalar	Açıklama
HFD	Hızlı Fourier Dönüşümü
DP	Doğru Pozitif
DN	Doğru Negatif
YP	Yanlış Pozitif
YN	Yanlış Negatif
YSA	Yapay Sinir Ağı
OKH	Ortalama Karesel Hata
ROC	Receiver Operating Characteristic
İE	İşlemci Eleman
İEÇ	İşlemci Eleman Çıkışı

1. GİRİŞ

20 KHz'den daha büyük olan frekanslara ultrasonik frekans denir ve insan kulağı bu frekansları duyamaz. Ultrasonik Doppler, hareketli yapıların ve özellikle vücuttaki kan akış hızının insan vücuduna zarar vermeden vücut dışından ölçümünde ve belirlenmesinde kullanılan önemli bir tekniktir. Bu amaçla ilk olarak yaklaşık 40 yıl önce kullanılmasına rağmen, taşınabilir Doppler kan akış ölçme cihazları ancak son 20 yıllık bir süre içinde geliştirilmiştir. Geliştirilen bu cihazlar sayesinde çok ince damarlarda bile kan akış hızı ve damar çapı ölçülebilmekte, damarda bir tıkanıklık veya genişleme varsa bu kolaylıkla tespit edilebilmektedir (1).

2. dünya savaşı sırasında, uçakların yerinin radarla tespit edilmesinden ilham alan bir çok ilim adamı, yansıyan ultrasonik dalganın, insan vücudundaki iç organların ve yapıların belirlenmesinde kullanabileceğini düşünmüştür. 1950'li yıllarda Amerika ve Avrupa'da farklı guruplar birbirinden bağımsız olarak oldukça farklı gayelerle değişik sahalarda araştırmalara başlamıştır. Amerika'da yapılan ilk araştırmalar çok genel olmuş ve ilk on yıl, tıbbi teşhis geleneğinde pratik uygulamalar için sonuçsuz kalmıştır (2).

Avrupalı araştırmacılar klinik problemlere doğru yönelmişler ve yapmış oldukları çalışmalar Amerikalı araştırmacılar kadar teorik olmamıştır. Bundan dolayı teşhise dayalı ultrasonik uygulamada Avrupa, Amerika'dan daha önde olmuştur. Mitral kapakçık hastalıkları 1954'den itibaren teşhis edilmeye ve çözümlenmeye başlamıştır.

Hertz'in (3) araştırmalarında ilk adım, kalp duvarı / kan ara yüzeyinin ultrasonik dalgayı, kaydedilen ve belirlenebilen bir mesafe gibi yansıttığını göstermek olmuştur. Bu bulgu, kan ve kas arasındaki akustik empedansın küçük oluşundan dolayı şüpheli kabul edilmiştir. Ultrasonik frekansın seçimi nüfuz etme ve seçicilik arasındaki bir uyuşma olarak ilk sırada önem taşımıştır. Bunu göz önüne alarak Hertz kardiyoloji için optimum olan 2.5 MHz'lik ultrasonik merkez frekansını seçmiştir (3).

1957’de Hertz, Almanya’da, Doppler cihazının ilk uygulamasını medikal bölümlerde gerçekleştirmiştir. Daha sonra sürekli dalga modda kaydedilen ilk Ekokardiyogram (Doppler sonogramı), Elektrokardiyogram ve kalp sesleri gibi diğer parametrelerle birlikte kaydedilmiştir. Daha sonraları prob teknolojisinde büyük ilerlemeler sağlanarak yüksek çözünürlüklü tarayıcılar gerçek zaman görüntüleme kullanılmaya başlanmıştır. 1973 yılında Johnson ve arkadaşları (4) elektronik gelişmeleri yakından takip ederek darbeli Doppler cihazını ilk defa, kalp kapaklarındaki kan akışını incelemek için kullanmışlardır.

Bulanık kümeler teorisini Lotfi A. Zadeh (5) 1965 yılında ortaya attıktan sonra, bu konu üzerinde pek çok alanda çalışmalar yapılmıştır. Bu alanların en önemlilerinden biri de tıptır. Yine Zadeh tarafından bulanık küme teorisinin tıp alanında kullanılabilirliği 1969 yılında açıklanmıştır (6). Kalmanson ve Stegall (7) 1975 yılında kardiovasküler sistemlerin pratik uygulamalarında bulanık küme teorisini kullanmayı önermiş, fakat kendilerinin o an için yeterli teknolojiye sahip olmadıklarını belirtmişlerdir. Joly ve arkadaşları (8) kardiyak fonksiyonlarının değerlendirilmesinde bulanık küme teorisinin kullanılması konusunda 1980 yılında çalışmışlardır. EKG verilerinin sınıflandırılması ve teşhisi konusunda, Degani ve Bortolan (9) ve Kerre (10) 1989’da, ilk çalışmaları yapmışlardır. Bu çalışmalarda patolojik bilgiler bulanık küme formuna getirilerek, istatistiksel ve deterministik yaklaşımlarla sınıflama yapılmıştır. 1990’lı yılların ortalarında kardiovasküler alanda bulanık küme kavramı ile ilgili yapılan çalışmalar artmıştır. Hudson ve arkadaşları (11) kalp hastalıklarının, bulanık ve hibrit sistemler ile teşhisi üzerine 1994 yılında çalışmışlar ve çeşitli kalp hastalıklarının teşhisini yapmayı başarmışlardır. Akay ve arkadaşları (12) 1994 yılında koroner arter hastalığının vücuda zarar vermeden sinirsel bulanık sistemle tespitini % 89 sınıflama oranı ile başarmışlardır. Cios ve arkadaşları (13) 1996 yılında kalbin tomografi görüntülerini bulanık mantık ile sınıflamış ve %94 başarı elde etmişlerdir. Koroner arter hastalıklarının bulanık sınıflaması konusunda, Jain ve arkadaşları (14) genetik tabanlı bulanık kural tabanı kullanarak, 1998 yılında %96’lık bir başarı elde etmişlerdir. Nauck ve Kruse (15) NEFCLASS sinirsel bulanık sınıflayıcı ile göğüs kanser verilerini sınıflamayı, 1999 yılında %95 oranında başarmışlardır. Güler ve öğrencileri (16, 17) bulanık mantık ve

genetik tabanlı bulanık sınıflayıcı ile kardiyak Doppler işaretlerinin sınıflandırılmasını başarılı bir şekilde gerçekleştirmişlerdir.

Kardiyak Doppler sonogramları uzman hekimler tarafından incelenerek kalp hastalıklarının teşhisi gerçekleştirilebilmektedir. Ancak bu sonogramlar Hızlı Fourier Dönüşümü (HFD) analizi sonucu elde edildiğinden, HFD analizinin yapısı gereği, kardiyak Doppler işaretlerine ait hızlı değişen yüksek frekanslı değişimlerin zaman domeninde tam olarak bölgelendirilememesine neden olmaktadır. Bu durum yanıltıcı spektrumların ortaya çıkmasına, yani belirgin olmayan sonogramların elde edilmesine sebebiyet vermektedir.

Bu çalışmada, kardiyak Doppler işaretleri HFD analizi sonucunda durağan hale getirilmiştir. Uzman hekimlerin daha doğru ve hızlı teşhis yapabilmesi için, kardiyak Doppler parametreleri çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcıya uygulanarak eğitilmiş ve sınıflandırılması gerçekleştirilmiştir.

Tezin ikinci bölümünde, kalbin kan akışındaki rolünün ne olduğu, HFD analizi ve ultrasonik Doppler'in çalışma mantığı açıklanmıştır. Ayrıca yapay sinir ağları ve NEFCLASS sinirsel bulanık sınıflayıcı hakkında bilgiler verilmiştir.

Üçüncü bölümde, aort kapakçığından kaydedilen kardiyak Doppler işaretlerinin HFD analizinden elde edilen sonuçları verilmiştir. Bunun yanında, sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı değerlerinin çok katmanlı algılayıcı ve NEFCLASS sinirsel bulanık sınıflayıcı ile sınıflanmasının sonuçları verilmiştir. Ayrıca, mitral kapakçıktan kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu eğrilerinden elde edilen parametreler, çok katmanlı algılayıcı ve NEFCLASS sinirsel bulanık sınıflayıcı ile sınıflandırılmıştır.

Dördüncü bölümde de tezle ilgili genel sonuçlar verilmiştir.

2. KARDİYAK DOPPLER İŞARETLERİ, YAPAY SİNİR AĞLARI ve SİNİRSEL BULANIK SINIFLAYICILAR


2.1. Kalbin Çalışması ve Kan Akış Hızı

Kalp, Şekil 2.1'de görüldüğü gibi iki ayrı pompadan oluşur. Sağ kalp kanı akciğerlere, sol kalp çevresel organlara pompalar. Bu iki kalp gözünden her biri, kulakçık ve karıncıktan ibaret iki boşluklu bir pompadır (18).

Kulakçıkların temel fonksiyonu karıncıklara geçiş yolları olmakla birlikte zayıf da olsa, kanın karıncıklara pompalanmasına yardımcı olurlar. Karıncıklar kanın akciğerlere ve çevresel dolaşıma gönderilmesinde esas görevi yaparlar. Kulakçık ve karıncıkların arasında yukarıdan aşağıya açılıp kapanan kapaklar vardır. Sol kulakçıkla sol karıncık arasında mitral kapak, sağ kulakçıkla sağ karıncık arasında da triküspit kapak mevcuttur.

Triküspit ve mitral kapakları sistol sırasında, kanın kulakçıklara geri dönmesini, sol karıncıktan çıkan aort ve sağ karıncıktan çıkan pulmoner arterlerin hemen başlangıç noktalarındaki aort ve pulmoner kapaklar ise diyastol esnasında kanın geriye, karıncıklara kaçmasını önler ve pasif olarak açılıp kapanırlar (19).

Kapakçıklarda daralma veya yetmezlik olması, kanın akış hızını ve düzenini değiştirmekte, böylece tüm vücut bundan olumsuz yönde etkilenmektedir. Kapakçıklarda daralma olduğunda kanın geçeceği mesafe daralmakta ve türbülanslı akış oluşmaktadır. Yetmezlik durumunda ise karıncıklardan bir miktar kan tekrar kulakçıklara geri kaçmaktadır. Doppler cihazları sayesinde kalp ve damarlardaki kan akış hızı ölçülebilmekte, hekime kapakçıklarla ilgili problem olup olmadığı hakkında ön bilgi verilebilmektedir.



Şekil 2.1. Kalbin yapısı

Akciğerlerde temizlenmiş olan kan, ana toplardamarlar yoluyla sol kulakçığa geçer ve 7-8 mmHg basınçtaki zayıf bir atrial kasılmayla sol karıncığa akar. Karıncık kasıldığında, kan kalbin sol kısmından sistemik dolaşıma pompalanır (20).

Kan sıvı olarak, sudan daha kalın bir şekilde gözükür ve çeşitli fiziksel tekniklerle araştırıldığında ise, farklı bileşenlerden oluştuğu bulunur. Kırmızı renge, kırmızı kan hücreleri (erythrocytes) neden olur, bunların boyutu 7 μm 'dir ve kanın %45'ini oluştururlar. 1 mm^3 kanda yaklaşık olarak 5×10^6 kırmızı kan hücresi vardır. Tipik yaşam süreleri 3 aydır ve her gün ortalama 10 milyarı ölmektedir. Temiz akışkan olan geri kalan yaklaşık %55'lik kısım kan plazma diye adlandırılır (19).

Kırmızı kan hücreleri ve plazma haricinde kanda beyaz kan hücreleri (leukocytes) gibi diğer bazı bileşenler de az miktarda bulunur. Bunların boyutları 9-15 μm arasındadır, bağışıklık sisteminin bir parçasıdır ve hastalıklarla mücadelede önemli rol oynarlar. Kanın 1 mm^3 ünde yaklaşık olarak 8000 beyaz kan hücresi bulunur. Vücuda bir hastalık bulaştığında beyaz kan hücrelerinin sayısı artar. Bir tip kan kanseri olan lösemi de beyaz kan hücresi aşırı derecede üretilir. Beyaz kan hücrelerinin farklı tipleri farklı enfeksiyonlara cevap verirler (20, 21).

Düzgün (laminar) ve düzensiz (türbülanslı) kan akışı

Kan kalpten taşınırken, atardamarlar kanı değişik dokulara pek çok defa taşımaktadır. En küçük kan damarları kılcal damarlardır. Bunlar çok küçüktürler ve milyonlarcası vücudumuzda mevcuttur (19).

Kan aorttan küçük atardamarlara giderken hızı azalmaktadır. Kan akış hızı, kanın taşındığı damarın toplam kesitsel alanı ile ters orantılıdır. Aorttaki ortalama hız yaklaşık 0,3 m/s iken, kılcal damarlarda bu hız 1 mm/s'dir. Kılcal damarlarda O₂ ve CO₂ değişimi yapıldığından bu düşük hız gazların difüzyonu için zaman sağlamaktadır.

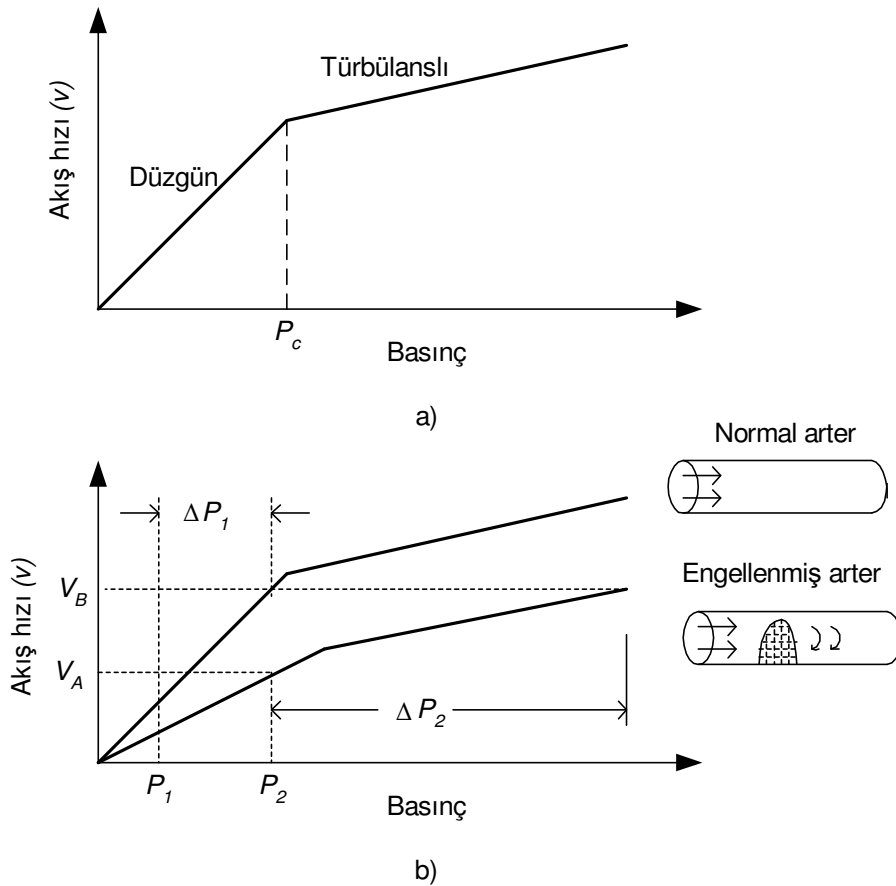
Pek çok kan damarındaki akış, yavaş yavaş, sessiz akan nehirdeki akışa, kanın kalp kapaklarından geçerken ki akışı ise hızlı, gürültülü akan nehirlerin akışına benzemektedir.

Düzgün akışın önemli bir karakteristiği sessiz olmasıdır. Eğer tüm kan akışı düzgün olsaydı, kalpten steteskop ile bilgi alınamazdı. Steteskop ile kalpteki türbülanslı akışların sesleri duyulur. Kan basıncı ölçümü sırasında kolluğun sıkıştırılması sonucunda koldan türbülanslı akış elde edilir. Sonuçta elde edilen titreşimler arterden steteskop yardımı ile duyulabilir (22).

Düzgün akıştaki kan, damar çeperleri ile kontak halindedir ve genellikle durağan haldedir. Bir nehrin kıyısındaki su akışı daha yavaşken, orta kısmında daha hızlıdır. Buna benzer olarak damarın dış katmanındaki kan daha yavaş akarken, iç katmandaki kan daha hızlı akmaktadır. Bu özellik, dolaşım sistemindeki kırmızı kan hücrelerinin dağılımından kaynaklanmaktadır.

Aorttaki hız aralığı 0-0,5 m/s dir ve sistol sırasında akış türbülanslı olmaktadır. Ağır egzersiz sırasında kalpten pompalanan kan 4 veya 5 kat artmakta ve kritik hız zamanın uzun bir periyodu olarak geçmektedir. Ağır egzersiz yapan kişilerin kalp sesleri dinlenmedeki kişilerininkinden farklıdır (23, 24).

Düzgün akış türbülanslı akıştan daha etkilidir. Bu durum Şekil 2.2a'da grafik olarak gösterilmektedir. Eğrinin eğimi, düzgün akış bölgesinde türbülanslı akış bölgesine göre daha büyüktür. Bu, basınçta artmaya neden olur ve düzgün akış hızı, türbülanslı akış hızına göre daha büyük bir artış gösterir. Arterde bir engelleme olduğunda kan akışında gözle görülür bir azalma meydana gelir (Şekil 2.2b). Normal bir arter için; V_A akış hızı, P_1 basınç değerlerine ihtiyaç vardır. Kısıtlanmış bir arter için daha yüksek olan P_2 basıncına gerek vardır. Eğer iki arterde akış hızları V_B değerine çıkarılmak istenirse, normal arter için gerekli basınç farkı ΔP_1 kadardır. Kısıtlanmış arterde türbülanslı akıştan dolayı, ΔP_2 'lik daha büyük bir basınç farkına ihtiyaç vardır.



Şekil 2.2. Kan akış hızı ve basınç ilişkisi. a)Düzgün ve türbülanslı akıştaki hız b)Normal ve engellenmiş arterdeki akış hızı.

Kan akışının bu özellikleri ve kalpteki olan problemler değişik metotlarla öğrenilebilir. Bu metotlardan biri de Doppler metodudur. Bu metotta damara ultrasonik bir işaret gönderilir, damardan yansıyan işaretin frekansı ile gönderilen işaretin frekansı arasındaki fark Doppler frekansını verir. Doppler frekansı akışla ilgili olup, spektral analizleri yapılarak akış hızına ait sonogramlar elde edilir.

2.2. Ultrasonik Doppler Prensipleri

Ultrasonik Doppler, cerrahi bir işlem gerektirmeden, vücuttaki hareketli yapıların hızını belirleme ve ölçmede kullanılan önemli bir tekniktir. Bu amaç için yaklaşık olarak kırk yıl önce kullanılmaya başlanmış ve son yirmi yıl içerisinde ise Doppler cihazlarının kullanımı yaygınlaşmıştır. Ultrasonik Dopplerin tıptaki ilk kullanımı, doğumda fetalın kalp atışlarını görüntüleme ve karotid arterindeki kan akışını değerlendirmek olmuştur. Günümüzde Doppler sistemleri kardiyoloji, nöroloji, radyoloji, doğum, pediatri ve cerrahi alanlarında da kullanılmaktadır. Görüntülenebilen çok ince damarlarda bile akış izlenebilmektedir. Ultrasonik Doppler ile kan akışının olması, olmaması, yönü ve karakteristiği belirlenebilmektedir. Doppler cihazlarından alınan sonuçların doğru bir şekilde yorumlanabilmesi için fiziksel mekanizmanın ve Doppler işaretlerinde kullanılan işaret işleme metotlarının tam olarak anlaşılması gereklidir (25, 26, 27).

Doppler Etkisi

Klinik uygulamaların geliştirilmesi ve anlaşılması açısından Doppler etkisini fiziksel olarak belirtmek gereklidir. Hareketten dolayı frekans veya dalgaboyundaki değişme Doppler etkisidir. Buradaki hareket, kaynak veya gözlemcinin hareketi olabilir. Gözlemci kaynağa göre hareketli ise gönderilen frekans ile gözlenen frekans farklı olmaktadır. Kaynak ile gözlemci birbirlerine doğru hareket ediyor ise gözlenen frekans gönderilen frekanstan daha fazladır. Kaynak ile gözlemci birbirlerinden uzaklaşıyor ise gözlenen frekans gönderilen frekanstan daha düşüktür. Bu durum, 1843 yılında Christian Doppler tarafından gözlenmiştir. Christian Doppler o

zamanda, Őu fizik sorusuna özüm bulmuŐtur: Neden bazı yıldızlar kırmızı ve bazıları mavi olarak görölmektedir (28). Yıldızların hareketli olmasından yola ıkararak, Doppler bu gözlemleri tanımlayabilecek bir denklem geliŐtirmiŐtir. Bu denklem, ışık kaynağı gözlemciden uzaklaŐıyor ise renk kırmızıya dođru kayar ve kaynak gözlemciye dođru hareket ediyor ise renk maviye dođru kayar düşüncesine dayanmaktadır. Bir dalganın hareketten dolayı, gözlenen frekansındaki deđiŐme Doppler etkisi olarak bilinmektedir. Kaynak ve gözlemcinin hareketli olması veya olmaması ile ilgili üç durum olabilir. İlk olarak, gözlemci hareketli olur ve kaynak durađandır. İkinci olarak, gözlemci durađan kaynak hareketlidir. Üçüncü durumda ise her ikisi hareketlidir. Kaynak ve gözlemcinin hareketli olması halinde biri referans noktası olarak seçilebilir. Böyle bir durumda, kaynak hareketli gözlemci durađan olarak düşünölebilir. Gözlemci kaynađa dođru hareket ediyor ise, artmış olan gözlenen (alınan) frekans Őu Őekilde belirtilir:

$$f_r = f_t \cdot \frac{c + v}{c} \quad [2.1]$$

burada f_t gönderilen frekans, v gözlemcinin hızıdır. Gözlemcinin hızı ile dalganın yayılma yönü arasında θ açısı var ise ifadede v yerine dalga yönündeki v 'nin bileŐeni olan $v \cos \theta$ konur:

$$f_r = f_t \cdot \frac{c + v \cos \theta}{c} \quad [2.2]$$

Gözlemci durađan ve kaynak dalganın hareketi yönünde v hızı ile hareket ediyor ise dalgaboyu kısalır. Sonuta gözlenen frekans:

$$f_r = f_t \cdot \frac{c}{c - v} \quad [2.3]$$

Aı dikkate alındıđında:

$$f_r = f_t \cdot \frac{c}{c - v \cos \theta} \quad [2.4]$$

Ultrasoniğin klinik uygulamalarında, ultrasonik dalga hareketli kan hücrelerinden saçılmaktadır. Yukarıda belirtilen etkiler birleştirilerek frekanstaki Doppler kayması elde edilir. Bu durumda gözlenen frekans şu şekilde verilir:

$$f_r = f_t \cdot \frac{c + v \cos \theta}{c} \cdot \frac{c}{c - v \cos \theta} = f_t \cdot \frac{c + v \cos \theta}{c - v \cos \theta} \quad [2.5]$$

Doppler kayması:

$$f_d = f_r - f_t = f_t \cdot \frac{c + v \cos \theta}{c - v \cos \theta} - f_t = \frac{f_t (c + v \cos \theta) - f_t (c - v \cos \theta)}{c - v \cos \theta}$$

$$f_d = \frac{f_t c + f_t v \cos \theta - f_t c + f_t v \cos \theta}{c - v \cos \theta}$$

$c \gg v$ olduğu için:


$$f_d = \frac{2f_t v \cos \theta}{c} \quad [2.6]$$

Doppler cihazının klinik uygulamalarında Şekil 2.3'de görüldüğü gibi vücuda bir işaret gönderilir ve ulaştığı hedeflerden saçılması veya yansması durumunda frekanstaki değişimler gözlenir. Bu şartlar altında ultrasonik frekansta bir kayma belirlenir:

$$f_d = f_t - f_r = \frac{2f_t v \cos \theta}{c}$$

Burada, f_t ve f_r sırası ile gönderilen ve alınan ultrasonik frekanslardır, v hedefin hızı, c ultrasonun ortamdaki hızı, θ ultrasonik dalga ile hedefin hareket yönü arasındaki açıdır. Belirtilen herhangi bir durumda c hızı ve gönderilen frekans f_t bilinmektedir. Böylece, bir hedefin hızı yukarıdaki ifadede şu şekilde bulunabilir:

$$v = \frac{Kf_d}{\cos \theta} \quad [2.7]$$



Şekil 2.3. Frekansın damara gönderilmesi ve yansıyan dalgalar.

burada, $K = \frac{c}{2f_i}$ olarak bilinen katsayıdır. θ açısı, tam olarak belirlenebilir ise hız hesaplaması doğru olarak yapılabilir.

Pratik uygulamalarda, Doppler kaymasını tek bir hedef değil aynı hızda hareket eden hedefler oluştururlar. Bundan dolayı, Doppler kayma işareti tek frekans bileşenli değil çok frekans bileşenli bir işarettir. Doppler kayma işareti kullanılacak ise bu işarete ait spektrum tam olarak yorumlanmalıdır.

2.3. Kardiyak Doppler İşaretlerinin Hızlı Fourier Dönüşümü ile Analizi

Periyodik sayısal bir işaret, bir Fourier serisi ile temsil edilebilir ve bir dalga şekli kendisinin Fourier katsayılarından yeniden elde edilebilir. Fourier analizinin önemi şuradadır; tek frekans bileşenli bir işarete bir çok fiziksel sistemin cevabı, diğer frekans bileşenlerinin genliğinden ve görüntüsünden bağımsızdır. Böyle sistemler,

giriş işaretinin büyüklüğündeki bir değişim çıkış işaretinde de aynı oranda değişim verdiği için, doğrusal sistemler olarak bilinir. Bundan dolayı örneğin, kan basıncı değişimi ile kan akışı arasındaki ilişki doğrusal ise (normal çevresel damarları göz önüne aldığımız için) ve verilen bir frekansta kan basıncı değişimi ile akış arasındaki ilişki biliniyorsa üç basit adımda kompleks bir basınç değişiminden akış hesaplanabilir. İlk olarak basınç değişiminden sinüzoidal (Fourier) katsayıları ayrılır, ikinci olarak her frekanstaki akış katsayıları (genlik ve faz) aynı frekanstaki basınç değişiminden hesaplanır, üçüncü olarak hesaplanan akış katsayıları tüm akış dalga şeklini vermesi için birbirleriyle toplanır (29).

Sonlu uzunlukta olan bir Doppler işaretinin Hızlı Fourier Dönüşümünü (HFD) almak için, mevcut işaret 2^n 'nin katları şeklinde 64, 128, 256 gibi çerçevelenir. Her bir çerçeveye karşılık düşen frekans spektrumu bulunurken pencereleme yapılır. Pencereleme sayesinde, gerçekte olmayan frekans bileşenlerinin spektrumda ortaya çıkması önlenir.

Ayrıca pencereleme işleminden sonra aynı Doppler işaretine, sıfır ekleme (Zero Padding) yapılır. Bu işlem spektrumda okunabilirliği artırmasına karşın, işlem yükünü de arttırmaktadır. Ayrık zamanlı periyodik bir işaretin ayrık Fourier dönüşümü Eşitlik 2.8'deki gibi tanımlanır,

$$X_k = \sum_{n=0}^{N-1} x(n) \exp\left(-jkn \frac{2\pi}{N}\right) \quad [2.8]$$

Buradaki X_k katsayıları ayrık Fourier katsayıları olarak adlandırılır. N çerçeve boyu; $x(n)$, zaman domenî giriş işaretidir. Bu işaretin frekans spektrumunu bulmak için Eş. 2.9'da görüldüğü gibi, ayrık Fourier dönüşüm katsayıları olan X_k sayılarının mutlak değerlerinin karelerinin logaritmaları alınır.

$$P(k) = 10 \log |X_k|^2 \quad [2.9]$$


İşaretin ayrık Fourier dönüşümü hesaplandıktan sonra güç spektrum yoğunlukları, Fourier dönüşümlerinin büyüklüklerinin kareleri alınarak hesaplanmaktadır. Ayrık bir işaretin güç spektrum yoğunluğu vektörü, $P(f)$ Eş. 2.10'daki bağıntı ile elde edilir.

$$P(f) = \frac{1}{N} \left[\sum_{n=1}^N x(n) \exp(-j2\pi fn) \right]^2 \quad [2.10]$$

Burada, N işaretin uzunluğu, $x(n)$ zaman domeni giriş işaretidir.

2.3.1. Kardiyak Doppler işaretlerinin kaydedilmesi ve analizi

Şekil 2.4'de görüldüğü gibi; ölçme sistemi beş bloktan ibarettir. Bunlar 2 MHz'lik ultrasonik dönüştürücü, Analog Doppler ünitesi (Toshiba sonolayer 140 A-Echo Device), Kaydedici (Sony), Analog / Sayısal arabirim kartı (Sound Blaster Pro - 16 bit) ve bir kişisel bilgisayardır (30, 31).




Şekil 2.4. Ölçüm sisteminin blok diyagramı.

Doppler işaretlerinin içerdiği spektral bilgiyi görsel olarak incelemek ve işaretin spektrumunun zamanla değişimini izlemek için kullanılan tekniklerin en yaygın olanı spektral analizdir. Bu teknikte zaman domenindeki kardiyak Doppler işareti uygun bir frekansta örneklenir. Elde edilen zaman örnekleri sabit sayıda örnek içeren çerçeveler halinde gruplanır (Şekil 2.5) (32).

Çerçevelerin oluşturulmasında yaygın olarak kullanılan çerçeve uzunlukları 64, 128 ve 256'dır. Bundan sonra da Hızlı Fourier Dönüşümü gibi spektral analiz tekniklerinden biri kullanılarak, her bir çerçeveye ait güç spektral yoğunluk

fonksiyonu olan $P(f)$ bulunur. Bu spektrum fonksiyonları zaman ekseninde yanyana dizildiği zaman kardiyak Doppler işaretinin spektrumunun zamana göre değişimini gösteren üç boyutlu sonogram grafiği elde edilir. Burada yatay eksen zamanı (t), dikey eksen frekansı (f), grafiğin renginin gri seviyesi ise ilgili frekans bileşeninin gücünü ($P(f)$) göstermektedir. Gri seviyesi siyaha doğru kaydıkça ilgili frekans bileşeninin gücünün arttığı, tersi durumda ise azaldığı anlaşılır (33, 34).

Sonogram yardımıyla kardiyak Doppler işaretinin içerdiği frekans bileşenlerinin spektral güçlerinin zamana göre değişimi kolaylıkla izlenebilir. Sonogram eğrisinin zarfı ise değişik kalp içi kan akış hastalıklarının incelenmesinde kolaylıklar sağlayan maksimum frekans eğrisidir (35).



Şekil 2.5. Örneklenmiş Doppler işaretinin çerçeveler halinde gruplanması


Kardiyak Doppler işaretinin sonogram analizi yapılmadan önce bir takım sorular göz önüne alınmalıdır (36):

1. İşaretin frekans sahası nedir?
2. Bir spektrumu hesaplamak için çerçeve uzunluğu ne olmalıdır?

Her çerçevenin optimum uzunluğu, işaretin durağan (stationary) oluşuna bağlıdır. Genel manada Doppler işareti durağan değildir. Ancak, düzgün akış söz konusu ise ve akış hızı çok yüksek değilse 10 ms ve daha yüksek zaman dilimleri için kardiyak Doppler işaretinin durağan olduğu varsayımı yapılabilir. Fakat akış hızının çok yüksek ve akışın çalkantılı olduğu durumlarda kardiyak Doppler spektrumunun değişimi çok hızlı olduğundan, bu varsayım geçerliliğini kaybeder. Bu durumda

işaretin durağan varsayılabilmesi için çerçeve süresinin azaltılması gerekir. Diğer yandan çok kısa çerçevelerin kullanılması, spektrum hesabında istatistiksel olarak yanlış sonuçlar verebilir. Bu yüzden kardiyak Doppler spektrum analizinde bunlar göz önünde tutulmalıdır (37-39).

Kardiyak Doppler dalgaşeklinde özellikler çıkartılırken, Şekil 2.6'da görüldüğü gibi, Sistol, Diyastol ve ortalama değerler elde edilir. Bunlardan yararlanarak da direnç indeksi, darbe indeksi ve sistol/diyastol değerleri Eşitlik 2.11, 2.12 ve 2.13'deki gibi bulunur (40).



Şekil 2.6. Doppler kan akış hızı dalgaşekli ve çok kullanılan üç indisi: S, sistolik tepe, D, diyastolik vadi ve O, ortalama kan akış hızı.

$$\text{Direnç indeksi} = (S - D) / S \quad [2.11]$$

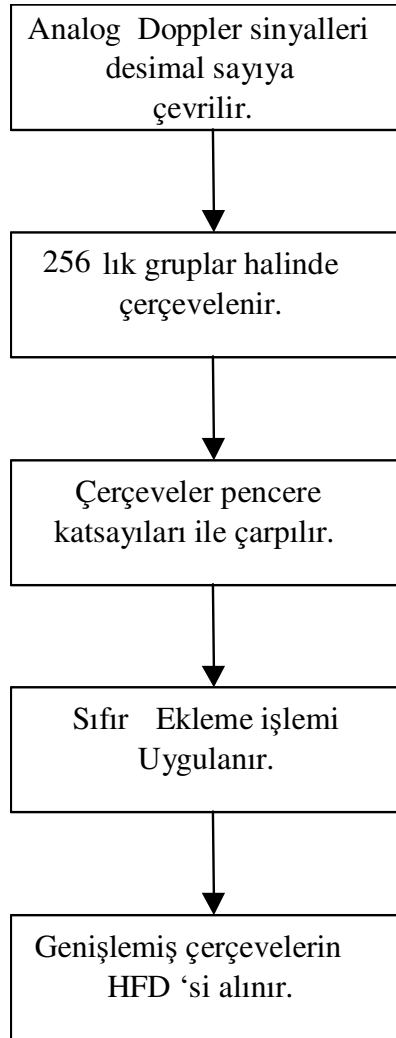
$$\text{Darbe indeksi} = (S - D) / O \quad [2.12]$$

$$\text{Sistol/diyastol oranı} = S / D \quad [2.13]$$

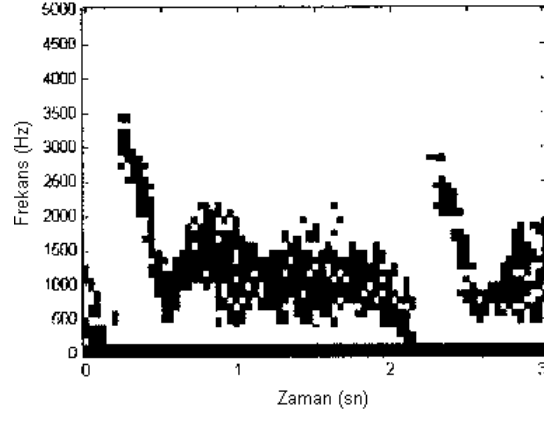
2.3.2. Kardiyak Doppler işaretlerine uygulanan HFD algoritması

Kardiyak Doppler işaretlerinin HFD parametrelerinin bulunması için Şekil 2.7'de şematik olarak gösterilen adımlar takip edilmektedir. Şekil 2.8'de de aort yetmezliği ve aort darlığına ilişkin örnek HFD sonogramları görülmektedir.

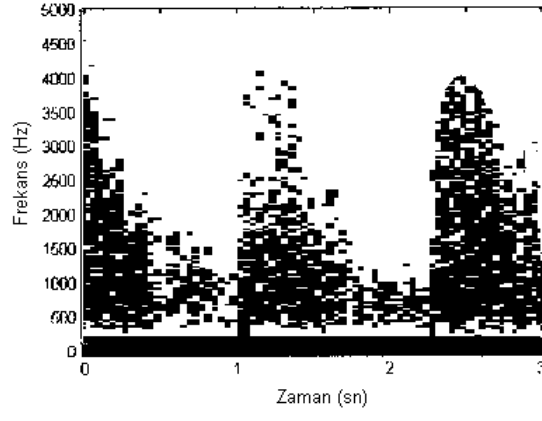
1. adımda bilgisayarın diskinde ASCII kodlu olarak kayıtlı olan ses dosyası desimal sayılara çevrilmektedir.
2. adım bu desimal sayıların 256'lık gruplar halinde çerçevelere ayrıldığı bölümdür.
3. adımda bu çerçeve sayıları pencere katsayıları ile çarpılarak HFD'nin hatası azaltılmaktadır.
4. adımda spektrumun genişlemesi için sıfır ekleme (Zero – Padding) yapılmaktadır.
5. adımda son olarak 256'lık çerçevelerin HFD si alınmaktadır.




Şekil 2.7. Kardiyak Doppler işaretlerine uygulanan HFD algoritması



a)



b)



c)

Şekil 2.8. HFD sonogramlarına örnekler a) Sağlıklı b) Aort yetmezliği
c) Aort darlığı

Şekil 2.8(a)'da sağlıklı bir kişinin kalp içi aort kapakçığından kaydedilen Doppler sinyaline ait sonogram görülmektedir. Sonogramın zarfı incelendiğinde iki tepe noktası olduğu ve bunların arasında bir genlik düşmesi olduğu görülür. Birinci tepe, mitral kapağın açılmasının hemen ardından sol kulakçığındaki basınç sebebiyle kanın sol karıncığa doğru hızla püskürmesi sonucu meydana gelir.

Kulakçığındaki kan karıncığa doğru geçtikçe kulakçık basıncı azalacağından ve kan akış hızı düşeceğinden sonogram genliğinde de bir düşme meydana gelir. Bu nokta iki tepe arasındaki çukur noktasıdır. Bu anda kulakçık kasılır ve halen kulakçık içerisinde bulunan bir miktar kan ikinci kez hızla karıncığa aktarılır. Bu durumda sonogram genliği ikinci kez yükselir ve kulakçığındaki kan azaldıkça genlikte azalır. Bütün bu olayların sonucunda Şekil 2.8(a)'da görülen ve zarfı M harfine benzeyen sağlıklı kişilerde görülebilecek sonogram ortaya çıkar.

Şekil 2.8(b)'de aort yetmezliği olan bir kişinin kalp içi aort kapakçığından kaydedilen Doppler sinyaline ait sonogram görülmektedir. Aort yetmezliği durumunda aort kapağı kapandıktan sonra, kanın bir kısmı geriye doğru kaçmaktadır. Bu geriye kaçan kan ultrasonik proba doğru yaklaştığından sonogramlarda sıfır seviyenin üzerinde pozitif pikler halinde görülmektedir. Sistolik kan basıncı yüksek olduğundan tepe noktalar yükselmektedir. Diastolik kan basıncı ise az olduğundan dolayı çukur nokta azalmaktadır. Bu şekilde tepe ve çukur noktalar arasındaki eğim artmaktadır.

Şekil 2.8(c)'de de, aort darlığı olan bir kişinin kalp içi aort kapakçığından kaydedilen Doppler sinyaline ait sonogram görülmektedir. Aort kapakçığında daralma olduğu zaman, sol karıncığın kapakçıktan kanı pompalaması ve vücuttaki kan damarlarına gönderebilmesi için çok yüksek basınç oluşturması gerekir. Bu da sonogramdaki birinci tepenin yüksekliğinin sağlıklı kişinkine göre daha fazla olmasına sebep olur. Ancak aort kapakçığının darlığı sebebiyle, aort kapakçığından aktarılan kan miktarı normaldekine göre daha azdır. Aort darlığı olan kişilerin sonogramlarında tepe ve çukur noktalar arasındaki eğim daha azdır.

HFD analizi, yapısı gereği kan akışındaki türbülans durumlarında ve yüksek hızlı değişen frekanslarda, pencere fonksiyonunun tarama sırasında sabit genişlikte olmasından dolayı, iyi bir frekans spektrumunun hesaplanamamasına ve belirsizliklere neden olmaktadır. Bu tez çalışmasında, bu durumun giderilmesi için, HFD analizi sonucu elde edilen kardiyak Doppler parametreleri (sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı) çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcı ile sınıflandırılarak, daha doğru ve hızlı teşhis yapılması amaçlanmıştır.

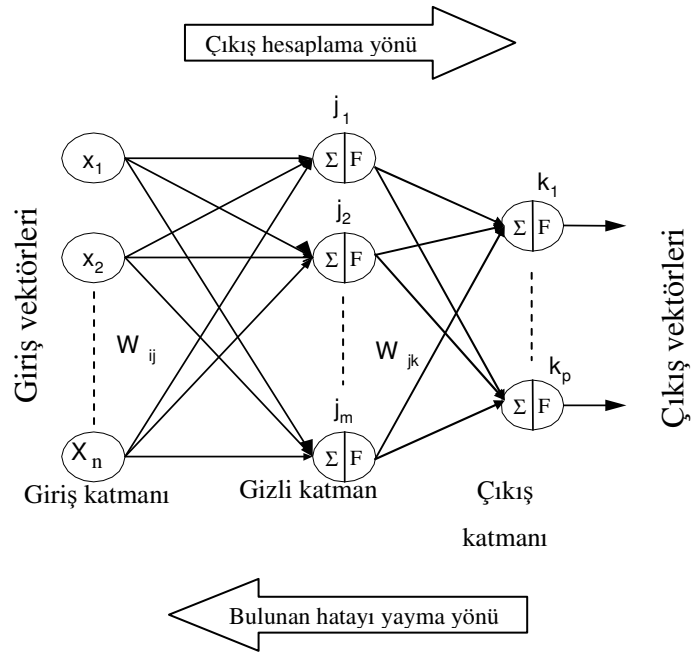
2.4. Yapay Sinir Ağları

Yapay sinir ağları yada kısaca YSA; insan beyninin çalışma sisteminin yapay olarak benzetimi çabalarının bir sonucu olarak ortaya çıkmıştır. Genel anlamda bir YSA insan beynindeki bir çok nöronun, ya da yapay olarak basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanması ile oluşan karmaşık bir sistem olarak düşünülebilir. Önceleri temel tıp bilimlerinde insan beynindeki nöronların matematiksel modelleme çabaları ile başlayan çalışmalar geçtiğimiz yirmi yıl içerisinde disiplinli bir şekil almıştır. YSA bugün fizik, matematik, elektrik ve bilgisayar mühendisliği gibi çok farklı bilim dallarında araştırma konusu haline gelmiştir. YSA'nın pratik kullanımı sadece, çok farklı yapıda ve formlarda bulunabilen enformasyon verilerini hızlı bir şekilde tanımlama ve algılama yeteneğine sahiptir. Ayrıca mühendislik uygulamalarında YSA'nın geniş çaplı kullanımının en önemli nedeni klasik tekniklerle çözümü zor problemler için etkin bir alternatif oluşturmasıdır (41-47).

YSA'lar, genel olarak birbirleri ile bağlantılı işlemci birimlerden veya diğer bir ifade ile işlemci elemanlardan (nöron) oluşurlar. Her bir sinir hücresi arasındaki bağlantıların yapısı ağı yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Kullanılan bir öğrenme kuralına göre, hatayı sıfıra indirecek şekilde, ağınlıklar değiştirilir.

2.4.1. Çok katmanlı algılayıcılar ve öğrenme algoritmaları

Bir çok katmanlı algılayıcı sinir ağı modeli, Şekil 2.9'da gösterilmiştir. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Bir çok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir.



Şekil 2.9. Geri yayılım çok katmanlı algılayıcı yapısı

Bir çok katmanlı algılayıcı modeli, bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır.

Burada giriş değerlerine önce toplama fonksiyonları uygulanır ve her bir işlem elemanının çıkış (İEÇ) değeri

$$IEÇ = \sum_{i=1}^N X_i W_{ij} - \theta_i \quad [2.14]$$

olarak bulunur. X_i i'inci girişi, W_{ij} j'inci elemandan i'inci elemana bağlantı ağırlığını ve θ_i eşik (threshold) değerini göstermektedir. Daha sonra bu çıkış değerleri

sigmoidal aktivasyon fonksiyonuna yani öğrenme eğrisine uygulanır. Sonuçta çıkış değeri aşağıdaki şekilde bulunur.

$$ÇIKIŞ = \frac{1}{1 + e^{-IEÇ}} \quad [2.15]$$

Transfer fonksiyonları olarak çoğunlukla, hiperbolik tanjant veya sigmoid fonksiyonu kullanılmaktadır. Bu işlemci elemanın çıkış değeri diğer işlemci elemanlarına giriş veya ağırlık çıkış değeri olabilir (42, 43).

Bilgi akışı ileri doğru olup, geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı uygulanan problemin giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanılarak belirlenir.

Çok katmanlı algılayıcı ağlarında, ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir (danışmanlı öğrenme). Örnekler giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitime algoritmasına göre, ağırlık çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağırlıklar değiştirilir.

İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur.

Geri Yayılım Algoritması

Bir çok uygulamada kullanılmış en yaygın öğretim algoritmasıdır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğretim algoritmasıdır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır.

Tipik çok katlı geri yayılım ağı, daima; bir giriş tabakası, bir çıkış tabakası ve en az bir gizli tabakaya sahiptir. Geri yayılım algoritması, gradyen azalan ve çok katmanlı algılayıcıları eğitmeye en çok kullanılan temel bir algoritmadır. Bu algoritmanın akış şeması Şekil 2.10'da verilmiştir. Ağın eğitimi için izlenmesi gereken temel süreç sırasıyla şu aşamalardan meydana gelmektedir.

1. Ağa bir giriş vektörü uygulanır ve buna ilişkin çıkış değeri hesaplanır,
2. Olması gereken çıkış değeri ile fiili çıkış değeri karşılaştırılır ve elde edilen fark hata ölçüsü olarak yorumlanır,
3. Hata değerini azaltabilmek için, her ağırlığın hangi yönde (- veya + yönde) değişmesi gerektiği belirlenir,
4. Her ağırlık değerinin ne kadar değiştirilmesi gerektiği hesaplanır,
5. 4. adımda hesaplanan bu miktarlara göre ağırlık değerleri yeniden düzenlenir,
6. Eğitim kümesindeki vektörler için hata değeri kabul edilebilir bir düzeye erişinceye kadar, ilk 5 adım tekrarlanır.

Eğitme işlemi ve eğitimden sonraki test işlemi bu akışa göre yapılır. Bu algoritma ile, i ve j kat işlem elemanları arasındaki ağırlıklardaki $\Delta w_{ji}(t)$ değişikliği hesaplanır. Bu ifade,

$$\Delta w_{ji}(t) = \eta \delta_j x_i + \alpha \Delta w_{ji}(t-1) \quad [2.16]$$

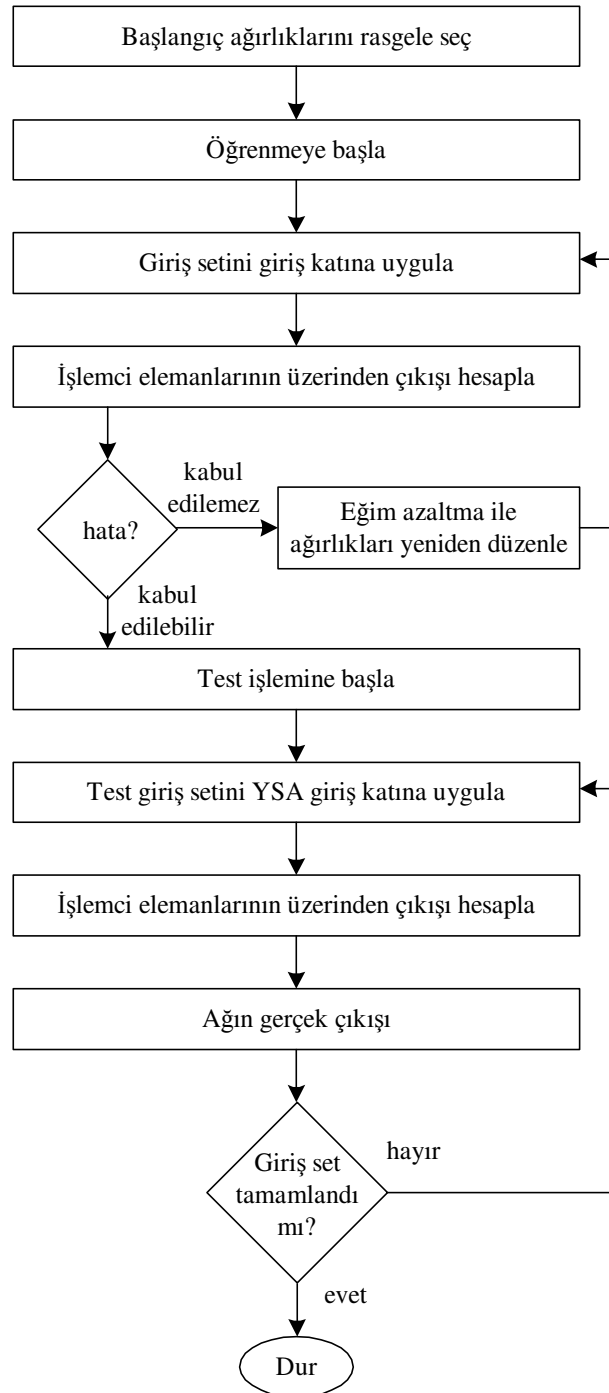
olarak verilir. Eşitlik (2.16)'da η öğrenme katsayısı, α momentum katsayısı ve δ_j ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Çıkış katı için bu faktör aşağıdaki şekilde verilir.

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad [2.17]$$

Burada, $net_j = \sum x_j w_{ji}$ ve $y_j^{(t)}$ ise j işlemci elemanının hedef çıkışıdır. Ara katlardaki İE'ler için ise bu faktör,

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) \sum w_{qi} \delta_q \quad [2.18]$$

olarak verilir. Ara katlardaki İE'ler için herhangi bir hedef çıkış olmadığından, Eşitlik (2.17) yerine Eşitlik (2.18) kullanılır. Bu duruma bağlı olarak çıkış katından başlayarak δ_j faktörü, bütün katlardaki İE'ler için hesaplanır. Daha sonra Eşitlik (2.16)'daki formüle bağlı olarak, bütün bağlantılar için ağırlıkların güncelleştirilmesi gerçekleştirilir (46).



Şekil 2.10. Çok katmanlı bir algılayıcı geri yayılım akış şeması

2.4.2. Kardiyak Doppler işaretlerinin çok katmanlı algılayıcı sinir ağına uygulanması

Sinir ağı mimarisinin, kardiyak Doppler işaretlerinin sınıflanması için uygun hale getirilmesi ve öncelikle ağın girişlerine uygulanacak verilerin en iyi öğrenmeyi sağlayacak şekilde seçilmesi gerekmektedir. Öğrenmeyi sağlayacak verilerin yeterli sayıda ve uygun eğitim vektörlerine dönüştürülmesinde kesin kurallar bulunmamaktadır. Problemlerin özelliklerine göre yeterli sayıda ve uygun eğitim vektörlerinin seçimi ancak tecrübe ile kazanılabilmektedir. Ancak yine de eğitim vektörlerinin seçimi sırasında kullanılabilir, bir takım kurallardan söz edilebilir.

Genel olarak ağın eğitilebilmesi için elde bulunan tüm kardiyak Doppler verilerinin kullanılması her zaman gerekmemektedir. Eğitim kümesi içerisinde yer alan bir miktar vektör, genellikle tüm vektörlerin %50'si, eğitim için kullanıldıktan sonra geriye kalan vektörlerden ağın test edilmesi için yararlanılmaktadır.

Aynı sınıfa ait olan bir çok farklı giriş vektörünün ağa uygulanması durumunda, sinir ağı bu vektörler arasındaki anlamlı benzerlikleri genelleme yaparak anahtar olarak öğrenmektedir.

Sinir ağı kardiyak Doppler giriş vektörlerinin özel bir sınıfı için yetersiz olarak eğitilirse, bu sınıfın üyeleri gerçek kullanım sırasında tanınmayabilir. Bu nedenle eğitim verileri, gerçek problemin tüm teşhis sınıflarını kapsayacak şekilde düzenlenmiş olmalıdır. Eğitim süreci sırasında, eğitim kümesinden vektör çiftlerinin tesadüfi olarak seçimi önem taşımaktadır. Bir sınıf için ağın eğitimini tamamladıktan sonra, bir başka sınıfın eğitimine geçilmesi halinde, ağ önceki sınıfların özelliklerini unutmaya başlayacaktır. Bu nedenle tüm sınıfları kapsayan eğitim vektörlerinin ağa tesadüfi bir sırada uygulanması, ağın öğrenimi için büyük önem taşımaktadır.

Çok katmanlı bir ağın kullanılması halinde üç katmanlı ağın yeterli olup olmadığı, her katmanda kaç düğüme yer verilmesi gerektiği yine tecrübe sonucunda ve çözülecek problemin özelliklerine bağlı olarak belirlenecektir. Kardiyak Doppler

işaretlerinden elde edilen parametrelerin sınıflanmasında, üç katmanlı ağ kullanılması yeterli bulunmuştur. Kardiyak Doppler işaretlerinin sınıflanması için kullanılacak giriş ve çıkış katmanında yer alacak düğümlerin sayısı doğrudan çözülecek problemin yapısına bağlıdır. Giriş vektöründe yer alan elemanların sayısı (örneğin; sistol, diyastol, direnç indeksi, darbe indeksi, sistol/diyastol oranı), giriş katmanının düğüm sayısını, bu vektöre bağlı olarak uygulanan ve olması gereken çıkış değerlerinin tanımlandığı çıkış vektöründeki eleman sayısı (örneğin; aort yetmezliği, aort darlığı, normal), çıkış katmanında yer alması gereken çıkış düğüm sayısını doğrudan belirleyecektir.

Buna karşılık gizli katmanda yer alacak düğüm sayısını bu kadar kesin bir şekilde belirleyebilmek mümkün değildir. Ancak unutulmaması gereken, gizli katmanda yer alacak her gereksiz düğümün bilgisayar çalışmasını uzatacağı, buna karşılık olması gerekenden daha az düğümün bulunması halinde de ağın öğrenme sürecini gerçekleştiremeyeceğidir. Yüzlerce giriş düğümünün bulunduğu bir ağda, gizli katman düğümlerinin sayısının, giriş düğümlerinin küçük bir yüzdesi olarak belirlenmesi genellikle tercih edilen bir yöntemdir. Gereğinden fazla düğümün tanımlandığı bir durumda, öğrenme süreci izlenerek, gereksiz düğümler elenebilir.

Kardiyak Doppler işaretlerinin sınıflanmasındaki ağırlık değerleri, eğitim sürecinin en başında $\pm 0,5$ değerleri arasında tesadüfi olarak belirlenmelidir. Ağın öğrenme hızını belirleyen η değeri için genellikle 0,05 ile 0,25 arasında küçük bir değerin atanması tercih edilir. Bu değerin gereğinden daha küçük belirlenmesi adım sayısının artmasına, tersi ise global maksimum noktaya erişilememesine neden olur. Sinir ağı modellerinin kardiyak Doppler işaretlerinin sınıflanması için kullanımında karşılaşılan diğer bir sorun da ağırlık uzayında bölgesel bir minimum noktaya erişilmesi ve bu noktanın problemin çözüm noktası olarak kabul edilmesidir. Ancak erişilen noktada elde edilen hata değeri kabul edilebilir düzeyde ise, bu noktanın bölgesel veya gerçek minimum olması büyük önem taşımayacaktır. Hata değeri kabul edilebilir bir düzeye erişmeden, ağın eğitimi sona erecek olursa, öğrenme parametresinin değerinin ve/veya gizli katmandaki düğüm sayısının değiştirilmesi faydalı olabilir.

Yapay sinir ağıının sınıflama sonuçlarının değerlendirilmesi gerekmektedir. Bunun için gerekli olan bazı yöntemler aşağıda anlatılmıştır.

2.4.3. Yapay sinir ağıının performansının değerlendirilmesi

Ağın öğrenmedeki başarısını değerlendirmek için gerçek ve tahmin edilen değerler arasındaki sapmalar ölçülür. Bu çalışmada sinir ağıının çıkışındaki nöronların değeri (hesaplanan teşhis) ile uzman hekimler tarafından daha önceden MR bulgularından belirlenen gerçek teşhis bilgisi karşılaştırılarak aradaki fark hata değeri olarak hesaplanmaktadır.

Ortalama Karese Hata (OKH) değeri, istenen ile hesaplanan ağ çıkışının birbirine ne kadar iyi uyup uymadığına karar vermek için kullanılır. Bu hata değeri dikkate alınarak çıkış katmanından giriş katmanına doğru bağlantıların ağırlıkları yeniden düzenlenir. OKH değeri öğrenmenin başlarında biraz büyük olabilir. Fakat öğrenmede adım sayısı arttıkça OKH azalacak ve sabitleşecektir. OKH değeri kabul edilebilir değerin altına düşünceye kadar devam edilen bu öğrenme tekniğine geri yayılım öğrenme tekniği denir.

Korelasyon katsayısı olan r ise $[-1 \ 1]$ aralığında bir değer olarak ağıın eğitimi hakkında bilgi vermektedir. Korelasyon katsayısının 1'e yakın değeri eğitimin ne kadar başarılı olduğunu göstermektedir.

OKH, ağıın istenen çıkış değerlerine ne kadar yaklaştığını belirlemek için kullanılır. Denetimli öğrenme için durma kriteri genellikle OKH üzerine kurulur. OKH bir eşik değerinin altına düştüğünde öğrenme durdurulur. Bir başka durma kriteri ise adımlar arasındaki hata değişiminin eşik değerinin altına düşmesi durumudur.

OKH değerinin belli bir değerin altına düşmesiyle sinir ağıının girişine uygulanan verilerin yapısını başarıyla öğrendiği kabul edilir. Böylece herhangi bir hastaya ait kardiyak Doppler parametreleri ağa uygulandığında ağıın çıkışında elde edilen sonuç uzman bir hekimin verdiği karar ile benzerlik taşımalıdır. Uzman hekimin teşhisi ile

sinir ağı çıkışında hesaplanan teşhis bilgisinin ne kadar benzediği bir çizelge üzerinde gösterilir. Sınıflama tablosu olarak adlandırılan bu çizelge incelenerek sinir ağının tahmin başarısı ölçülebilir.

Ayrıca sinir ağının sınıflama performansını belirleyebilmek için duyarlılık (sensitivity) ve belirlilik (specificity) analizi yapılır. Duyarlılık değeri uzman hekim ile aynı hastalık teşhis sayısının; uzman hekimin yapmış olduğu toplam hastalık teşhis sayısına bölünmesi ile elde edilir. Doğru Pozitif oranı olarak da adlandırılan duyarlılık;

$$\text{Duyarlılık} = DPO = \frac{DP}{DP + YN} \quad [2.19]$$

formülüyle hesaplanır. Doğru Pozitif (DP) hastalıklı verilerin doğru sınıflandırılma sayısını, Yanlış Negatif (YN) sağlıklı verilerin yanlış sınıflandırılma sayısını ifade etmektedir. Böylece hastalıklı verilerin ne oranda başarı ile tahmin edilebildiği görülür. Diğer taraftan belirlilik değeri uzman hekimler ile aynı sağlıklı teşhis sayısının; uzman hekimlerin yapmış olduğu toplam sağlıklı teşhis sayısına bölünmesi ile elde edilir. Doğru Negatif oranı olarak da adlandırılan belirlilik;

$$\text{Belirlilik} = DNO = \frac{DN}{DN + YP} \quad [2.20]$$

formülüyle hesaplanır. Doğru Negatif (DN) sağlıklı verilerin doğru sınıflandırılma sayısını, Yanlış Pozitif (YP) ise hastalıklı verilerin yanlış sınıflandırılma sayısını belirtmektedir. Belirlilik sayesinde de sağlıklı verilerin hastalıklılardan ne oranda ayrılabilirdiği görülür.

Sınıflandırma başarısı ölçümünün grafiksel olarak yapılabilmesi için test sonucu elde edilen çıkış verileri analiz edilerek ROC (Receiver Operating Characteristic) eğrisi hesaplanır. Doğru ve yanlış sınıflama bilgisine bakılarak belirlilik ve duyarlılık

arasındaki ilişki bu grafikte görülebilir. Ayrıca ROC eğrisi altında kalan alan da hesaplanarak sinir ağının performansı ölçülebilir.

Hastalardan elde edilen kardiyak Doppler parametreleri öğrenme ve test aşamalarında kullanılmak üzere değişik oranlarda olmak üzere iki ayrı gruba ayrılırlar. Burada dikkat edilmesi gereken bu iki grup içinde belli bir teşhis grubunun ağırlık kazanarak sinir ağını dengesiz eğitilmesine sebep olmaması için her teşhis grubundan aynı oranda veri alınmaya çalışılmalıdır. Öğrenme gerçekleştirildikten sonra test grubundaki veriler de sinir ağına uygulanarak sinir ağının sınıflama başarısı ölçülmelidir.

Yapay sinir ağlarında öğrenme esnasında yapılması gereken en önemli konulardan biri de öğrenme katsayısı ve momentum teriminin ayarlanmasıdır. Öğrenme katsayısı 0,01 ile 1 aralığında seçilebilen sabit bir sayıdır. Ağırlıkların çok yüksek tutulması yüzünden yapay sinir ağının öğrenme davranışı bozulabilir. Bunu önleyebilmek için öğrenme katsayısının küçük tutulması gerekir. Öte yandan küçük öğrenme oranı ise öğrenme işlemi yavaşlatmaktadır. Bu nedenle momentum öğrenme tekniği için adım büyüklüğünün ve momentum katsayısının ağırlık öğrenmesi için uygun olarak belirlenmesi gerekir. Bu parametrelerin dikkatlice ayarlanması ile başarılı sonuçlar elde edilebilir.

Bu tez çalışmasında, kardiyak Doppler işaretlerinden elde edilen parametreler ayrıca NEFCLASS sinirsel bulanık sınıflayıcı ile de sınıflandırılmıştır. NEFCLASS sinirsel bulanık sınıflayıcı ile bulunan teşhis sonuçlarının anlaşılabilirliği ve yorumlanabilirliği diğer sistemlere göre daha fazla olmaktadır. Bu amaçla kullanılacak sinirsel bulanık sınıflayıcıya ait bilgiler aşağıda sunulmuştur.

2.5. Sinirsel Bulanık Sınıflayıcılar

Sinirsel bulanık sınıflayıcılar, sinir ağları ile bulanık sistemlerin birleşimidir. Bu iki model ilk etapta kendi arasında bağımsız bir alana sahiptir. Ancak ikisinin birleşimi, çoğu problemin çözümü için yararlar sağlamaktadır.

Üyelik fonksiyonunun değer kümesi (0-1) aralığında sürekli her gerçek sayıyı alabilecek şekilde tanımlanmış ise, bu kümeye "Bulanık Küme" denir. Bulanık kümeler üyelik fonksiyonları ile temsil edilirler. X klasik evrensel kümeyi, x ise bu kümeye ait genel bir elemanı göstermektedir. A gibi bir alt kümenin oluşturulabilmesi için, tanım kümesinde verilen değerlere bağlı olarak değer kümesinde (0-1) aralığında her gerçek sayı sağlayan karakteristik fonksiyona "üyelik fonksiyonu" denir. A gibi bir kümenin üyelik fonksiyonu μ_A ile gösterilir. Tanım kümesindeki değerlere bağlı olarak, değer kümesinde elde edilen değerlere "üyelik derecesi" adı verilir. Bu, A kümesine ait bir x elemanın üyelik derecesine göre yorumlanması aşağıdaki gibi yapılmaktadır (48-52).

- 1) x elemanının A kümesine ait üyelik derecesi "1" ($\mu_A(x)=1$) ise x , A kümesinin mutlak elemanıdır.
- 2) x elemanının A kümesine ait üyelik derecesi "0" ($\mu_A(x)=0$) ise x , A kümesinin elemanı değildir.
- 3) x elemanının A kümesine üyelik derecesi (0-1) aralığındaki değerlerden herhangi bir değeri almış ise, iki durum incelenir;
 - a) $\mu_A(x)$ değeri 1' e yakın bir değer ise, x elemanının A kümesine üyeliği daha güçlüdür.
 - b) $\mu_A(x)$ değeri 0' a yakın bir değer ise, x elemanının A kümesine üyeliği zayıftır. Üyelik derecesi, bulanık küme için tanımlanmış üyelik fonksiyonunun tipine göre değişecektir.

Bir sinirsel bulanık sınıflayıcı olan NEFCLASS, veriden bulanık sistem oluşturan dilsel bir yaklaşım metodudur ve yerel parametre değişimleri, sezgisel (heuristic) veri sürme algoritması ile hesaplanır. Bu işlem başka metotlarla da yapılabilir, fakat NEFCLASS model, oluşturulan sınıflayıcının yorumlanabilirliği üzerine odaklanmıştır.

NEFCLASS modelinin ana amacı okunabilir bir sınıflayıcı oluşturmak ve kabul edilebilir bir doğruluğu yakalamaktır. Yorumlanabilir bir bulanık sistem şu özelliklere sahip olmalıdır:


- Şart cümlesinde birkaç değişken ile birkaç anlamlı kural,
- Her bir değişken için birkaç anlamlı küme,
- Kural ağırlıkları olmamalı,
- Dilsel terimler, bulanık kümeleri temsil etmeli,
- Sadece normal bulanık kümeler kullanılmalıdır.

Bu özellikler sayesinde, eğitim verisinden bir bulanık sistem oluşturulurken, pek çok sınırlama meydana gelmektedir. Eğer bulanık sistem için yüksek performans ana amaç ise, sistemin veriye yüksek doğrulukla uyması gerekmektedir. Bu yaklaşımdaki bir bulanık sistem de yukarıdaki özellikleri sağlayamaz ve aslında bu bir siyah kutu modeli olur. İlk önce okunabilirliğin mi, yoksa doğruluğun mu daha öncelikli olduğuna karar vermek gerekir. NEFCLASS çözümleri okunabilirliğe daha çok önem vermektedir (53).

2.5.1. NEFCLASS modelin yapısı

NEFCLASS sinirsel bulanık sınıflayıcı, özel üç katmanlı ileri beslemeli bir sinir ağı gibi görülebilir. Burada;

- İlk katman giriş değişkenlerini ifade eder,
- Gizli katman bulanık kuralları ifade eder,
- Üçüncü katman çıkış değişkenlerini ifade eder ki, her bir sınıf için bir ünite vardır,
- Üniteler aktivasyon fonksiyonu olarak t-norm veya t-conorm kullanır,
- Bulanık kümeler, bulanık birleşim ağırlıkları ile kodlanır.



Şekil 2.11. NEFCLASS modelin yapısı.

Şekil 2.11 bu sinir ağı yapısını göstermektedir ki, genellikle paralel yapıyı ve veri akışının nasıl olduğunu belirtmek için kullanılır. Burada öğrenme geri yönde, sınıflama ise ileri yönde olmaktadır. Fakat unutulmamalıdır ki, bu sadece bir bakış açısındaki gösterimdir. Bu sistem bir sinir ağı değildir. Hibrit bir sinirsel bulanık sistemdir ve birbiriyle birleştirilmiştir.

Şekil 2.11'de R_k kuralları ve $A_j^{(i)}$, $W(x_i, R_k)$ ağırlığını ifade etmektedir. Burada j indeksi bulanık kümelerdeki parçaları belirtmektedir. NEFCLASS bazı birleşimlerde paylaşılmış ağırlıkları kullanır (elips şeklinde gösterilen ağırlıklar). Bu yolla her bir dilsel değer için (örneğin "x1 pozitif büyüktür") bulanık küme olarak sadece bir gösterimi belirtmesi sağlanır. Birleşimler aynı giriş ünitesinden gelen bir ağırlığı paylaşır, çünkü onun anlamı nerede olursa aynıdır. Fakat farklı değişkenlerin anlamı farklı olabilir (54, 55).

$W(R_k, c_m)$ kural R_k dan çıkış ünitesi c_m ye olan bağlantıdır. Bu bağlantıların ağırlığı ya 0 (bağlantı yok) yada 1 (bağlantı var) şeklindedir. Her bir kural ünitesi bir çıkış ünitesine bağlanmıştır. Çıkış aktivasyonu maksimum işlemi ile hesaplanır.

Öğrenme işlemi, sinir ağı olan sistemlerde özel bir öneme sahiptir ve "ağın eğitilmesi" şeklinde de ifade edilir. Burada sınıflayıcı oluşturulduktan sonra ağırlıklar değiştirilerek, öğrenme işlemi gerçekleştirilir.

İlk öğrenme adımında; sınıflayıcının yapısı, veri tabanına uyacak şekilde oluşturulur. İkinci öğrenme adımında; eğitim işlemleri sonucunda sistemin parametreleri değiştirilir ve yorumlanabilirlik kaybedilmeden doğruluk artırılarak, sınıflayıcı tamamlanır (56).

2.5.2. Kural tabanının öğrenme algoritması

Bir NEFCLASS sistemi, kümelerdeki parçadan oluşturulabilir ve öğrenme ile yeniden düzenlenebilir veya boş bir kural tabanı ile başlayıp eğitime verisinden oluşturulan kurallarla doldurulur. Her bir giriş değişkeni için hangi tip küme kullanılacağına ve kaç parçaya ayrılacağına karar verilmelidir. Her bir değişkendeki ve dilsel terimdeki bu parçalılık sınıflayıcı tarafından kullanılır. Bazı değişkenler küçük, büyük şeklinde ifade edilebilecekken, bazıları da daha parçalı bir şekilde oluşturulabilir. Gizli katmandaki kural düğümlerinin maksimum sayısı olan k_{max} da ayrıca belirlenebilir. Her bir sınıf için en az bir kural olmalıdır. NEFCLASS modelde k_{max} kendi kendine de uygun bir değer olarak bulunabilir (57).

Üçgen üyelik fonksiyonunun tanımlanması için kabul edilen üç parametre şunlardır:

$$\mu : \mathbb{R}^n \rightarrow \mu(x) = \begin{cases} \frac{x-a}{b-a} & \text{Eğer } x \in [a, b], \\ \frac{c-x}{c-b} & \text{Eğer } x \in [b, c], \\ 0 & \text{Diğer durumlar} \end{cases} \quad [2.21]$$

Ek olarak her bir değişken için sol ve sağ üyelik fonksiyonları düz olarak uzatılıp yarı yamuk üyelik fonksiyonu elde edilebilir.

Bir NEFCLASS sistemi şu şekilde düşünülebilir:

- n giriş ünitesi, x_1, \dots, x_n ,
- $k \leq k_{\max}$ başlangıç kural ünitesi, R_1, \dots, R_k ,
- m çıkış ünitesi, c_1, \dots, c_m ,
- bir öğrenme kümesi $L = \{(p_1, t_1), \dots, (p_s, t_s)\}$, s adet örüntü içerir ki, her biri bir tane giriş örüntüsü $p \in R^n$ ve bir tane hedef örüntüsünden $t \in \{0, 1\}^m$ oluşur.

NEFCLASS' ın başlangıçta $k \leq k_{\max}$ bulanık kuralla oluşturduğu düşünülürse, NEFCLASS'ın kural tabanı, her bir p örüntüsü için bulanık kümelerdeki birleşimin en yüksek üyelik derecesi bulununca tamamlanır. Bulanık kümelerin bu birleşimi kuralların şart kısmını oluşturur. Eğer şart daha önce oluşturulmadı ise listeye eklenir. Her bir şart için uygun sonuç hesaplanırken, tüm örüntülerin üyelik dereceleri her bir sınıf için eklenir. Sonuç ise sınıf etiketlerindeki en büyük toplamdır. Her bir eğitme örüntüsü bir defa işlendikten sonra, k' kuraldan oluşan bir kural tabanı elde edilir. Eğer $k' > k_{\max}$ ise sadece en iyi k_{\max} kural (en iyi kural öğrenme) veya her bir sınıf için en iyi k_{\max} / m kural (her sınıf için en iyi kural öğrenme) korunur, diğer tüm kurallar kural tabanından silinir. En iyi kurallar, her bir kural için performans değerlerinin hesaplanması ile belirlenir. Eğer kural, örüntüyü doğru olarak sınıflayabiliyorsa, derecesi performans değerine eklenir, değilse derecesi çıkarılır (15).

Kural öğrenme algoritması

For L nin her bir örüntüsü (p, t) do

Begin

For her bir giriş do

$$\mu_{ji}^{(i)} \text{ Bul, } \mu_{ji}^{(i)}(p_i) = \max \{ \mu_j^{(i)}(p_i) \};$$

Şartları oluştur, A = ($\mu_{j_1}^{(1)}, \dots, \mu_{j_n}^{(n)}$ *);*

If A şart listesinde değilse then A yı şart listesine ekle;

End;

For L nin her bir örüntüsü (p, t) do

For her bir şart A_j do

Begin

c = p nin sınıf indeksi;

$$C_j(c) = C_j(c) + A_j(p) \quad (*dereceyi ekle*)$$

End;

For her bir şart A_j do

Begin

c = argmax {C_j(i)};

R_j kuralını şart A_j ve sonuç c ile oluştur;

R_j yi kural tabanı adayı listesine ekle;

$$\text{Performans}_j = C_j(c) - \sum C_j(i)$$

End;

If "en iyi kural öğrenme"

Then for i = 1 to k_{max} do

Begin

R = argmax { Performans_j}

R yi kural tabanına ekle;

R yi kural tabanı adayı listesinden sil;

End;

Else if "her sınıftaki en iyi kural öğrenme"

Then for her bir sınıf c do

For i = 1 to k_{max} / m do


Begin

R = argmax { Performans_j}

R yi kural tabanına ekle;

R yi kural tabanı adayı listesinden sil;

End;



Şekil 2.12. Kural öğrenmeden sonraki sınıflama.

Öğrenme algoritması bir ızgara yapısı içinde gösterilebilir. Şekil 2.12 kuralların ızgara yapısından nasıl seçildiğini göstermektedir. Burada, sistemde üç kural oluşturulmuş, ayrıca üç örüntü sınıflanamamıştır.

Şekil 2.12'de görüldüğü gibi sonuç kötü olmamakla beraber iyileştirmeye ihtiyaç duymaktadır. Örüntü 1 ve 2 yanlış sınıflanmış ve üç örüntü de hiç sınıflanamamıştır. Bunu düzeltmek için bulanık kümelerin kaydırılması ve düzenlenmesi gerekmektedir:

- Örüntü 1'in doğru sınıflanabilmesi için
 - ✓ b bulanık kümesi üstten biraz küçültülmeli,
 - ✓ d bulanık kümesi alttan biraz genişletilmeli,
 - ✓ c' bulanık kümesi soldan biraz genişletilmeli.
- Örüntü 2'nin doğru sınıflanabilmesi için
 - ✓ c' bulanık kümesi sağdan biraz küçültülmeli,
 - ✓ e' bulanık kümesi soldan biraz genişletilmeli.
- Sınıflanamayan üç tane şeklin sınıflanabilmesi için
 - ✓ b' bulanık kümesi sağdan genişletilmeli.

2.5.3. Bulanık kümelerin eğitimi algoritması

NEFCLASS'ın denetimli öğrenme algoritması, öğrenme kümesi L boyunca, bitiş kriteri sağlanana kadar (kabul edilebilir sınıflama olduğunda, veya hata düşmüyor ise) bulanık kümeleri uyarlamak için çalışır. Bir örüntü uyarlandıktan sonra, her bir çıkış ünitesi için hata elde edilir. Bu hataya dayanarak, her bir aktif kural ünitesi için, derecesinin büyük veya küçük olduğuna karar verilir. Böylece üyelik fonksiyonu tanımlanır ve bulanık küme doğru bir şekilde ayarlanır. Bulanık küme üzerinde herhangi bir kısıtlama yoksa, bu işlemler yapılabilir. Bazı kısıtlamalar şunlardır:

- Bulanık kümeler aynı derece ile örtüşmelidir,
- Bulanık kümeler birbirinin içine girmemelidir,
- Bulanık kümeler simetrik olmalıdır,
- Üyelik dereceleri 1'e tamamlanmalıdır vb.

Bu kısıtlamalardan bir veya birkaçı seçilebilir. Kısıtlamalar kural tabanının yorumlanmasına yardımcı olmasına rağmen, sınıflamadaki performans kaybına neden olabilmektedir (57-58).

Üçgen üyelik fonksiyonu için öğrenme algoritması

Repeat

Sonraki örüntüyü geriye doğru işle (p, t);

For her bir çıkış ünitesi c_i *do*

$ec_i = t_i - \text{aktivasyon}(c_i)$;

For her bir R ünite kuralı, $\text{aktivasyon}(R) > 0$ *do*

Begin

$e_R = \text{aktivasyon}(R) \cdot (1 - \text{aktivasyon}(R)) \cdot \sum (W(R, c) \cdot ec_i)$

$j = \text{argmin} \{W(x_i, R)(p_i)\}$

$\mu = W(x_j, R)$

$\delta_b = \sigma \cdot e_R \cdot (c_\mu - a_\mu) \cdot \text{sgn}(p_i - b_\mu)$;

$\delta_a = -\sigma \cdot e_R \cdot (c_\mu - a_\mu) + \delta_b$;

$\delta_c = \sigma \cdot e_R \cdot (c_\mu - a_\mu) + \delta_b$;

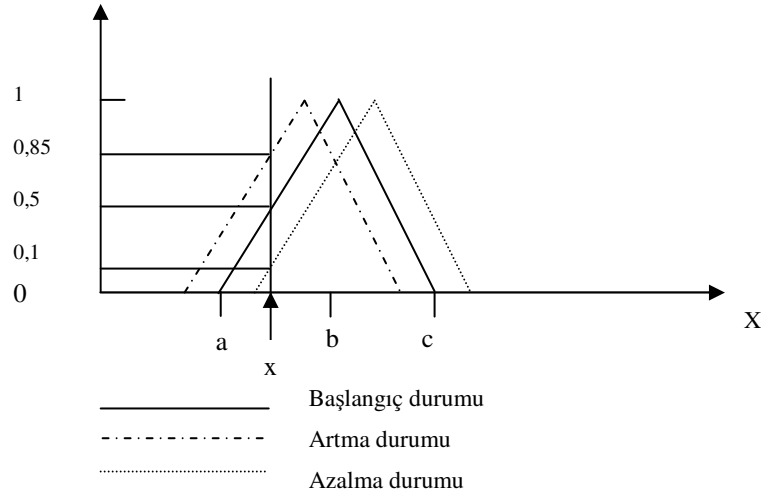
$\delta_a, \delta_b, \delta_c$ ile μ değerini, kısıtlamaları dikkate alarak düzenle;

end;

until bitiş kriteri;

Bulanık kümelerin öğrenme işlemi basit sezgiseldir. Üyelik fonksiyonlarının kaydırma sonuçları, destek noktalarını büyütür veya küçültür (Şekil 2.13). Üyelik derecelerinin değiştirilmesi çok küçük aralıklarla yapılmalıdır.

Öğrenme algoritmasındaki e_R nin hesaplanmasındaki toplama işlemi aslında gerekli değildir, çünkü her bir kural ünitesi, sadece bir çıkış ünitesine bağlıdır. Fakat bu işlem, modeli uyarlanabilir kural ağırlıkları kullanılabilir şekilde değiştirmeye kolaylık sağlar. NEFCLASS modelde kural ağırlıklarının kullanılabilmesi mümkünken, yorumlanabilirlik açısından bu pek kabul görmemektedir. İyi bir sınıflama yapabilmek için kural ağırlıklarını kullanmaya gerek yoktur (59). Bu yüzden öğrenme işlemindeki hata değeri sıfıra ulaşamaz, bir bitiş kriterine göre işlem son bulur.




Şekil 2.13. Bulanık kümelerin değiştirilmesi.

Bulanık kümelerin değiştirilmesi işlemi, üyelik derecelerinin de değişmesini, yani artıp veya azalmasını beraberinde getirmektedir.

Şekil 2.14 üyelik fonksiyonlarının öğrenme algoritmasından sonra, sınıflama sonuçlarındaki artışı göstermektedir. Burada öğrenme işleminde herhangi bir kısıtlama kullanılmamıştır. Bulanık kümeleme işleminin bu şekilde yapılmasının, yorumlanabilirliği azalttığı da görülmektedir. Öğrenme işlemi diğer kısıtlama

kuralları ile denenirse daha yorumlanabilir sonuçlar elde edilebilir. Bu örnekte okunabilirliğin ne kadar önemli olduğu açıkça gözükmektedir (58).



Şekil 2.14. Bulanık küme öğrenmesinden sonraki sınıflama.

Sinir ağları ile karşılaştırıldığında NEFCLASS daha basit bir öğrenme stratejisi kullanır. Burada kuralları öğrenmek için vektör kuvantalama kullanılmamakta ve üyelik fonksiyonları eğim inişi metodu ile eğitilmemektedir. Bulanık kuralların bulunması işlemi başlangıçta verilen sahte kural tabanından, girişteki bulanık kümelerden uyanların seçilmesi ile sağlanır.

NEFCLASS yapısına ve veri akışına bakıldığında, bulanık kümeler geri yayılım benzeri bir algoritma ile eğitilmektedir. Buradaki geri yayılım terimi öğrenme işleminin düşüncesini belirtmek için kullanılmıştır, yoksa direkt geri yayılım algoritması kullanılmamaktadır. Geri yayılım algoritması, çıkışta hesaplanan hatayı, çıkıştan girişe doğru bir mimari şeklinde düzeltmeyi sağlamaktadır. Yerel parametreleri değiştirmek için hata değeri kullanılır. Sinir ağları genellikle geri yayılım işlemini eğim inişi ile yaparlar. NEFCLASS ise herhangi bir eğim değeri hesaplamaz. Ek olarak, NEFCLASS'ın uyarlanabilirliği sinir ağları ile karşılaştırıldığında daha kısıtlıdır. Bu kısıtlama başlangıçta verilen bulanık kümelerin parçalanışından ve bulanık kümeler üzerinde belirli sınırlar dahilinde işlem yapılmasından kaynaklanmaktadır (59).

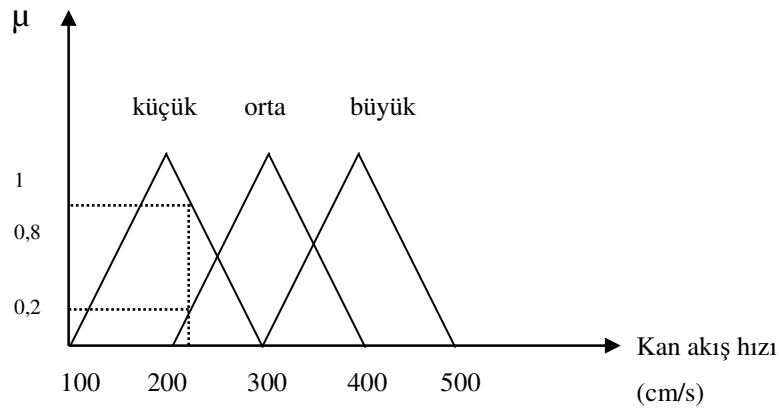
2.5.4. Kural tabanının budanması

NEFCLASS modelin öğrenme algoritması pek çok sınıflama probleminde iyi sonuçlar vermektedir. Aslında öğrenme sonuçlarının iyi yorumlanabilir olması her zaman mümkün değildir, özellikle de büyük boyutlu problemlerde bu durum geçerlidir. Bulanık sınıflayıcı kullanmanın bir amacı yorumlanabilirlik olduğundan, elde edilen sonuçları basitleştirmek için NEFCLASS sinirsel bulanık sınıflayıcının öğrenme algoritmasının geliştirilmesine ihtiyaç vardır (53). Sınıflayıcının yorumlanabilirliğini arttırmak için şu budama stratejileri kullanılır:

- Aşağıda belirtilen durumlarda, şarttaki dilsel terimler silinebilir:
 - ✓ Değişken sınıflama için önemli değilse: Bu durumda giriş değişkenlerinden sınıflama sonucuna fazla etki etmeyenlerin bulunması gerekir. Bunun için sınıf bilgileri ile birlikte giriş değişkenlerinin ilişkisi kullanılır. Değişkenlerin düşük ilişkiye sahip olup olmadığı test edilir, eğer düşükse tüm kuralların şart cümlesinden silinir. Tekrardan bulanık kümeler eğitilir. Eğer bu durum sınıflama sonucunu iyileştirdiyse, başka bir değişken için aynı işlemler tekrarlanır. İyileştirme sağlanmadıysa son sınıflayıcı kabul edilir.
 - ✓ Bulanık kümenin kullandığı terimler fazla ise: Eğer değişken ikiden fazla kümeye bölünmüşse, öğrenme süresinde kayıplara neden olur. Bu gibi durumlarda bazı kümeler gereksizdir ve kurallardan silinir. Tekrardan bulanık kümeler eğitilir. Eğer bu durum sınıflama sonucunu iyileştirdiyse, başka bir değişken için aynı işlemler tekrarlanır. İyileştirme sağlanmadıysa son sınıflayıcı kabul edilir.
- Sınıfın bulunması için kullanılan kurallardan katkısı az olanlar silinir: Her bir kural için sınıflama sonucuna hangi derece ile katkısının olduğu bulunur. Küçük katkısı olan kurallar silinir.

2.6. Kardiyak Doppler Parametrelerinin NEFCLASS ile Sınıflandırılması

Bulanık mantık temel olarak insan düşünüş şeklini örnek almaktadır. Dolayısıyla bu mantığın küme elemanları, insan mantığına çok yakın yada aynı olan elemanlardır. Bulanık mantıkta yine geleneksel mantıkta olduğu gibi “0” ve “1” değerleri vardır. Ancak bulanık mantık yalnızca bu değerlerle yetinmeyip, bunların ara değerlerini de kullanarak örneğin bir hızın yalnızca hızlı yada yavaş olduğunu belirtmekle kalmayıp ne kadar hızlı yada yavaş olduğunu da söyler. Bulanık mantıkta olaylar klasik mantığın tersine daha esnektir. Bu haliyle bulanık mantık hızlı – yavaş, büyük –küçük gibi esnek niteleyicilerle yumuşatarak gerçek dünyaya uyarlar. Örneğin kan akış hız değerimiz 100 ile 500 cm/s arasında değer alıyor ise ve biz bu değerleri bulanık kümelere bölmek istiyorsak Şekil 2.15’deki gibi küçük, orta ve büyük şeklinde üç kümeye ayırabiliriz. Hastamızın kan akış hızı 220 cm/s ise bu değer küçük kümesine 0,8 üyelik derecesi ile, orta kümesine ise 0,2 üyelik derecesi ile ve büyük kümesine ise 0 üyelik derecesi ile uymaktadır.



Şekil 2.15. Klasik kümelerin bulanık küme haline getirilmesi

X evrensel kümeyi, x bu kümeye ait genel bir eleman ve $\mu_A(x)$ ise A kümesine ait x elemanının üyelik derecesini gösterebilir. Bu duruma göre A bulanık kümesi;

$A = \{x, \mu_A(x) \mid x \in X\}$ biçiminde gösterilir.

Örneğimizde; $\mu_{\text{küçük}}(220) = 0,8$, $\mu_{\text{orta}}(220) = 0,2$ ve $\mu_{\text{büyük}}(220) = 0$ olarak gösterilebilir.

Bu tez çalışmasında kardiyak Doppler parametrelerinin sınıflandırılması için, yetmezlik, darlık ve normal olmak üzere 3 sınıf kullanılmıştır. Aort yetmezliği durumunda aort kapağı kapandıktan sonra, kanın bir kısmı geriye doğru kaçmaktadır. Bu geriye kaçan kan ultrasonik proba doğru yaklaştığından sonogramlarda sıfır seviyenin üzerinde pozitif pikler halinde görülmektedir. Sistolik kan basıncı yüksek olduğundan tepe noktalar yükselmektedir. Diastolik kan basıncı ise az olduğundan dolayı çukur nokta azalmaktadır. Bu şekilde tepe ve çukur noktalar arasındaki eğim artmaktadır.

Aort kapakçığında daralma olduğu zaman, sol karıncığın kapakçıktan kanı pompalaması ve vücuttaki kan damarlarına gönderebilmesi için çok yüksek basınç oluşturması gerekir. Bu da sonogramdaki birinci tepenin yüksekliğinin sağlıklı kişininkine göre daha fazla olmasına sebep olur. Ancak aort kapakçığının darlığı sebebiyle, aort kapakçığından aktarılan kan miktarı normaldekine göre daha azdır. Aort darlığı olan kişilerin sonogramlarında tepe ve çukur noktalar arasındaki eğim daha azdır.

Kardiyak Doppler işaretlerinden özellikler çıkartılırken sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı değerleri elde edilmiştir. Bu değerler NEFCLASS sinirsel bulanık sınıflayıcıya giriş değişkeni olarak uygulanmıştır. Bu yüzden kuralların şart kısmında 5 tane bağımsız değişken ve kuralların sonucunda da 3 adet bağımlı değişken bulunmaktadır. Sonuçta kuralların biçimi şu şekildedir:

Eğer	Sistol kan akış hızı	küçük ve
	Diyastol kan akış hızı	büyük ve
	Direnç indeksi	küçük ve
	Darbe indeksi	küçük ve
	Sistol/Diyastol oranı	küçük ise Aort yetmezliği'dir.

Bulanık kümeler kavramı ile bulanık sınıflandırmada, istatistik metotları gibi yerleştirme yapılmamaktadır. Bulanık sınıflandırma, benzer amaçları elde etmek için

farklı yollar önerir. Eğer karar sistemi, bulanık sınıflandırıcı ile yapılmış ise genellikle aşağıdaki avantajları göz önünde bulundurmak gerekir:

- Belirsiz bilgiler kullanılabilir,
- Sınıflandırıcı, dilsel kurallar içindeki şekillerde yorumlanabilir,
- Uygulama noktasından bakıldığında ise, anlamak ve uygulamak oldukça kolaydır.

Bulanık sınıflandırıcılar, sinir ağlarına ve en yakın komşu sınıflandırıcısına alternatif olarak görülebilir (54).

Bulanık kümelerin kesişim ve birleşim operatörlerinin seçilmesi önemlidir. Kesişim operatörleri için minimum gereksinimleri yerine getiren fonksiyonlara “t-normları” denir. t-normları ve t-normlarının çiftesi olan t-conormlar birleşim operatörlerinin temel tanımlamalarıdır (53). Bu çalışmada kullanılan NEFCLASS-model için kullanılan minimum değer aralığı:

$$T_{\min}(a,b)=\min\{a,b\} \text{ dir.}$$

Bulanık kurallar

Kardiyak Doppler parametrelerinin sınıflandırılması için bulanık kuralların sahip olduğu genel biçim şu şekildedir:


$$R_r: \text{Eğer } x_1, A_{j1}^{(1)} \text{ ve } \dots, x_n, A_{jn}^{(n)} \text{ ise } (x_1, x_2, \dots, x_n) \in C_j \text{ dir.}$$

Burada, x_1, \dots, x_n sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranından meydana gelen giriş değişkenleridir. $A_{j1}^{(1)}, \dots, A_{jn}^{(n)}$ ifadeleri küçük, orta ve büyük olmak üzere dilsel terimlerdir. $C_j \subseteq R^n$, örüntü (sonuç) ifadesinin alt kümesidir ve j. sınıfı göstermektedir. Sonuç ifadesi olarak yetmezlik (aort ve mitral),

darlık (aort ve mitral) ve normal sınıfları kullanılmaktadır. R_1, \dots, R_k sınıflandırma kural tabanıdır ve k adet bulanık kural bulunmaktadır.

Şekil 2.16'da k kuralları ve n giriş parametrelerini gösterecek şekilde, kural tabanının grafiksel sunumu görülmektedir.

Bulanık kontrol kurallarında, sonuç kısmı da bir bulanık küme olmasına rağmen, bir bulanık sınıflayıcıda kuralın sonucu, bir sınıfa denk gelen keskin bir değerdir. Bu değer t – norm (T_{\min}) ile hesaplanır. Tüm kurallar üzerinde de t – conorm (\perp_{\max}) işlemi yapılarak Şekil 2.16'da görülen sınıflama sonucu elde edilir (53).



Şekil 2.16. Maximum ve minimum operatörleriyle bulanık kural tabanı ve değerlendirilmesi

Kardiyak Doppler parametrelerinin bulanık sınıflayıcı ile sınıflandırılmasında üyelik fonksiyonları seçimi ve veri alanı bölümlendirilmesi, iyi çözülmesi gereken iki problemdir. Bulanık kümelerin veri alanı üzerinde simetrik ve düzenli dağıtılmaması da, sınıflama problemlerinde başarıyı arttırmaktadır.

Kural tabanı oluşturulurken 3 ihtimal göz önüne alınmıştır:

- Sistem kurallardan bağımsız olarak açılır ve öğrenme problemi çözülene kadar yeni kurallar oluşturulur. Yeni bir kuralın ortaya çıkması kural tabanı akışıyla tamamen yeterli seviyede olmayan bir örüntünün ortaya çıkmasıyla tetiklenir (59-61). Eğer üyelik fonksiyonları uygun bir şekilde seçilmemiş ise, bu yaklaşım geniş bir kural tabanı oluşturur.
- Sistem tüm kurallar ile başlar, değişkenlerin bölümlenmesi yapılır ve yetersiz kurallar kural tabanından silinir (57, 58). Bu prosedür için kişisel kuralların performans değerlendirmelerine ihtiyaç duyulur ve çok az kuralla sonuç elde etmek mümkündür.
- Sistem rasgele seçimli, sabit sayılı kurallardan oluşan kural tabanı ile açılır. Öğrenme işleminde kurallar yenilenirler. Bunu yapmak için kural tabanı doğruluğunun her bir basamakta kontrol edilmesi gerekir. Dezavantajı, sabit sayılı kuralları olmasıdır. Ek olarak, kuralların silinmesi ve yeni kuralların elde edilmesi için veri analizi gerçekleştirilmiş olmalıdır (53, 62, 63).

3. BULGULAR ve İRDELEME

Bu çalışmada, çeşitli hastaların aort kapakçığından elde edilen kardiyak Doppler işaretlerine HFD analizi uygulanmıştır. Bunun sonucunda sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı parametreleri elde edilmiştir. Ayrıca, mitral kapakçıktan kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu analizi yapılarak 10 adet parametre elde edilmiştir. Elde edilen bu parametreler, çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcıya giriş değerleri olarak verilmiş; darlık, yetmezlik veya normal durumlarına göre sınıflamaları yapılmıştır. Böylece hekime aort ve mitral kapakçık hastalıklarının teşhisinde yardımcı olabilecek bir sistem geliştirilmiştir.

3.1. Aort Kapakçığından Kaydedilen Kardiyak Doppler İşaretlerinin HFD Analizi Bulguları

Aort yetmezliği, aort darlığı ve sağlıklı olan toplam 60 hastadan kaydedilen kardiyak Doppler işaretlerinin spektrum analizleri yapılarak, her hastaya ait sonogram elde edilmiştir. Sonogramların elde edilmesi sırasında spektrum analizi için Hızlı Fourier Dönüşümü (HFD) metodu kullanılmıştır.

Doppler cihazının örnek hacmi, aort kapakçığına odaklanarak her bir hastadan 6'şar saniyelik Doppler işaretleri kaydedilmiştir. Spektral analiz yapılabilmesi için 10 KHz'de örneklenen işaretler eşit zaman aralıklarında (uzunlukta) çerçevelere ayrılmıştır. Bu çalışmada çerçeve uzunluğu 256 olarak alınmış, pencereleme işleminde de Hanning pencereleme kullanılmıştır.

Bu çalışma sonucunda elde edilen spektral eğriler karakterize edilerek, sistol, diyastol, direnç indeksi, darbe indeksi, sistol/diyastol değerleri ve bunların t test sonuçları Çizelge 3.1'de gruplandırılarak gösterilmiştir. t testi sonucunda verilerin hastalık gruplarına göre önemli farklılıklar gösterdiği anlaşılmıştır (64).


Elde edilen her bir spektral eğrinin çevrim dışı oluşma süresi 6 saniyede gerçekleştirilmiştir. 55 ve 58 yaşında sağlıklı kişilere ait spektral eğri örnekleri Şekil 3.1 ve 3.2'de görülmektedir. Bu spektral eğriler incelendiğinde birinci tepe (sistol), mitral kapağın açılmasının hemen ardından sol kulakçıktaki basınç sebebiyle kanın sol karıncığa doğru hızla akması sonucunda meydana gelir. Kulakçıktaki kan, karıncığa doğru geçtikçe kulakçık basıncı azalacağından ve kan akış hızı düşeceğinden spektral eğri genliğinde de bir düşme meydana gelir. Bu nokta iki tepe arasındaki çukur noktadır. Bu anda kulakçık kasılır ve hemen kulakçık içerisinde bulunan bir miktar kan ikinci kez hızla karıncığa aktarılır. Bu durumda eğri genliği ikinci kez yükselir (diyastol) ve kulakçıktaki kan azaldıkça genlikte azalır. Tüm bu olayların sonucunda Şekil 3.1 ve 3.2'de görülen ve zarfı M harfine benzeyen sağlıklı kişilerde görülen spektral eğri ortaya çıkar.

60 ve 63 yaşında aort yetmezliği olan kişilere ait spektral eğriler Şekil 3.3 ve 3.4'de görülmektedir. Aort yetmezliğinde sistol ve diyastol sağlıklı kişilere göre artmakta, ayrıca spektral eğri zarfında bozulmalar olmaktadır. 57 ve 62 yaşında aort darlığı olan kişilere ait spektral eğriler Şekil 3.5 ve 3.6'da verilmiştir. Şekil 3.6'da görüleceği gibi aort darlığı durumunda türbülanslı akıştan dolayı kan akış hızı 450 cm/s değerine (bazı örneklerde daha da yüksek) ulaşmaktadır.


Çizelge 3.1. Hastalıklara ait istatistiksel değerler

	Kontrol grubu (normal)	Aort Darlığı	P<	Aort Yetmezliği	P<
S (cm/s)	150±30	350±150	0,001	300±100	0,001
D (cm/s)	80±20	200±80	0,01	175±75	0,01
Direnç indeksi	0,46±0,07	0,43±0,09	0,01	0,41±0,06	0,05
Darbe indeksi	0,59±0,08	0,55±0,07	0,05	0,52±0,07	0,05
Sistol/diyastol	1,88±0,7	1,75±0,6	0,05	1,71±0,6	0,05


* P değerleri kontrol grubu ile yapılan karşılaştırmalar sonucu elde edilmiştir.




Şekil 3.1. 55 yaşında sağlıklı kişiye ait spektral eğri (kişi no: 5)




Şekil 3.2. 58 yaşında sağlıklı kişiye ait spektral eğri (kişi no: 17)




Şekil 3.3. 60 yaşında aort yetmezliği olan kişiye ait spektral eğri (kişi no: 26)



Şekil 3.4. 63 yaşında aort yetmezliği olan kişiye ait spektral eğri (kişi no: 33)



Şekil 3.5. 57 yaşında aort darlığı olan kişiye ait spektral eğri (kişi no: 45)

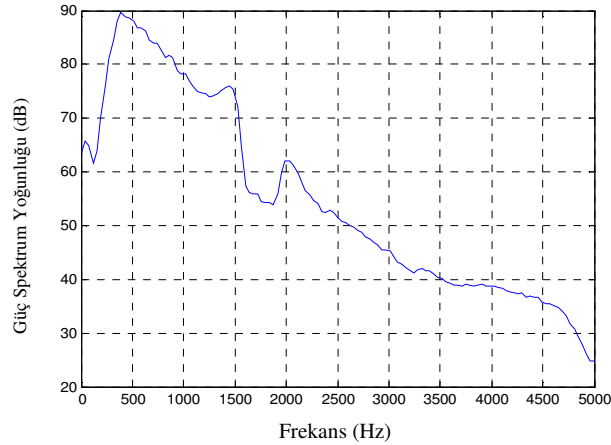


Şekil 3.6. 62 yaşında aort darlığı olan kişiye ait spektral eğri (kişi no: 52)


3.2. Mitral Kapakçıktan Kaydedilen Kardiyak Doppler İşaretlerinin Güç Spektrum Yoğunluğu Analizleri

Bu çalışmada, mitral yetmezliği, mitral darlığı ve sağlıklı olan toplam 60 hastanın mitral kapakçığından kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu analizleri yapılarak, her hastaya ait güç spektrum yoğunluğu eğrileri elde edilmiştir. Güç spektrum yoğunluğu analizi sonucu elde edilen eğrilerden 500'er Hz'lik artışlara karşılık gelen güç spektrum yoğunluğu değerleri (toplam 10 tane) çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcıya giriş vektörü olarak uygulanmıştır. Çıkış vektörü olarak ise mitral darlığı, mitral yetmezliği ve normal değerler kullanılmıştır.

Şekil 3.7 ve 3.8'de, 59 ve 62 yaşındaki sağlıklı kişilerin mitral kapakçığından kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu eğrileri görülmektedir. Şekil 3.7 ve 3.8 'deki sağlıklı kişilerin mitral kapakçıklarındaki kan akış hızı fazla yüksek olmadığı için frekans arttıkça spektral yoğunluk hızlı bir şekilde düşmektedir.




Şekil 3.7. 59 yaşında sağlıklı kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 7)




Şekil 3.8. 62 yaşında sağlıklı kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 12)

Şekil 3.9 ve 3.10'da, 60 ve 65 yaşındaki mitral yetmezliği olan kişilerin mitral kapakçığından kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu eğrileri görülmektedir. Şekil 3.9 ve 3.10 'da görüldüğü gibi mitral yetmezlik olan kişilerin düşük frekanslardaki güç spektrum yoğunluğu azalmakta iken, yüksek frekanslarda güç spektrum yoğunluğunda hızlı düşmeler görülmemektedir.




Şekil 3.9. 60 yaşında mitral yetmezliği olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 28)

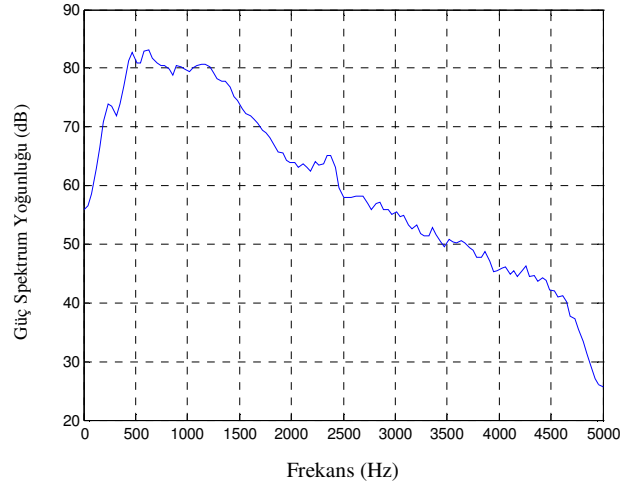


Şekil 3.10. 65 yaşında mitral yetmezliği olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 35)

Şekil 3.11 ve 3.12'de, 58 ve 61 yaşındaki mitral darlığı olan kişilerin mitral kapakçığından kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu eğrileri görülmektedir. Şekil 3.11 ve 3.12'de görüldüğü gibi, mitral darlığı olan kişilerde düşük frekanslardaki güç spektrum yoğunluğu azalmakta iken, yüksek frekanslarda güç spektrum yoğunluğunda hızlı düşmeler görülmemektedir. Daralma bölgesinde kan akışı hızlandığı için Doppler kayma frekanslarında artış gözlenmektedir.



Şekil 3.11. 58 yaşında mitral darlığı olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 48)



Şekil 3.12. 61 yaşında mitral darlığı olan kişiye ait güç spektrum yoğunluğu eğrisi (kişi no: 56)

3.3. Kardiyak Doppler İşaretlerinin Çok Katmanlı Algılayıcı Sinir Ağı ile Sınıflandırılması

Aort ve mitral kapakçıktan kaydedilen kardiyak Doppler işaretlerinin spektral analizleri yapılarak, öğrenme ve test aşaması için her bir kapakçıktan toplam 60'ar giriş vektörü elde edilmiştir. Kapakçıklardan kaydedilen işaretler için istenen çıkış değeri

[1 0 0] = Yetmezlik

[0 1 0] = Darlık

[0 0 1] = Normal

vektörleri ile tanımlanmıştır.

Bu çalışmada, aort ve mitral kapakçık için iki ayrı uygulama gerçekleştirilmiştir. Öğrenme algoritması olarak momentum katsayılı geri yayılım kullanılmış ve transfer fonksiyonu olarak tanh seçilmiştir. Momentum katsayısı 0,7 ve adım büyüklüğü 1 olarak alınmıştır.

Öğrenme sonrası sinir ağına test vektörleri uygulanmış ve sinir ağı ile ilgili Çizelge 3.2 ve 3.3'deki sonuçlar elde edilmiştir. Çizelge 3.2'de de görüldüğü gibi aort yetmezliklerinin sınıflanmasında 9 tanesi doğru, 1 tanesi yanlış, normallerin ve aort darlıklarının ise tamamı doğru olarak sınıflandırılmıştır. Mitral kapakçık çalışmasında ise, mitral yetmezliklerinin ve normallerin sınıflanmasında 9 tanesi doğru, 1 tanesi yanlış, mitral darlıklarının ise tamamı doğru olarak sınıflandırılmıştır.

Çizelge 3.3'deki test performans sonuçları incelendiğinde, OKH değerleri aort kapakçığı çalışmasında daha düşük, r değerleri ise daha yüksek olduğundan aort kapakçığı çalışmasının mitral kapakçık çalışmasına göre daha başarılı sonuçlar verdiği görülmektedir.

Sınıflama performansını ölçebilmek için bu sonuçların istatistiksel olarak değerlendirilmesi gerekir. Test sonuçlarının istatistiksel yorumlaması Çizelge 3.4'de verilmiştir. Aort kapakçığı çalışmasında 5 adet giriş değişkeni, mitral kapakçık çalışmasında ise 10 adet giriş değişkeni kullanılmıştır. Giriş değişkeninin fazla olması sınıflama performansını olumsuz yönde etkilemiştir. HFD analizi sonucu elde edilen parametrelerin (sistol, diyastol, direnç indeksi, darbe indeksi, sistol/diyastol oranı) giriş değişkeni olarak kullanıldığı aort kapakçığı çalışmasında, 10 adet güç spektrum yoğunluğu değerinin giriş değişkeni olarak kullanıldığı mitral kapakçık çalışmasına göre daha yüksek bir başarı oranı elde edilmiştir.

Çizelge 3.2. Test sonuçlarının sınıflama tablosu

<i>Çıkış / İstenen</i>	<i>Aort kapakçığı</i>			<i>Mitral kapakçık</i>		
	<i>Yetmezlik</i>	<i>Darlık</i>	<i>Normal</i>	<i>Yetmezlik</i>	<i>Darlık</i>	<i>Normal</i>
<i>Yetmezlik</i>	9			9		
<i>Darlık</i>	1	10		1	10	1
<i>Normal</i>			10			9

Çizelge 3.3. Test performans sonuçları

<i>Performans</i>	<i>Aort kapakçığı</i>			<i>Mitral kapakçık</i>		
	<i>Yetmezlik</i>	<i>Darlık</i>	<i>Normal</i>	<i>Yetmezlik</i>	<i>Darlık</i>	<i>Normal</i>
OKH	0,0325	0,0213	0,0176	0,0315	0,0494	0,0387
NOKH	0,1664	0,1713	0,0783	0,1419	0,2224	0,1744
OMH	0,0602	0,0561	0,0472	0,0908	0,0893	0,0612
r	0,8903	0,9455	0,9775	0,9314	0,8951	0,9189

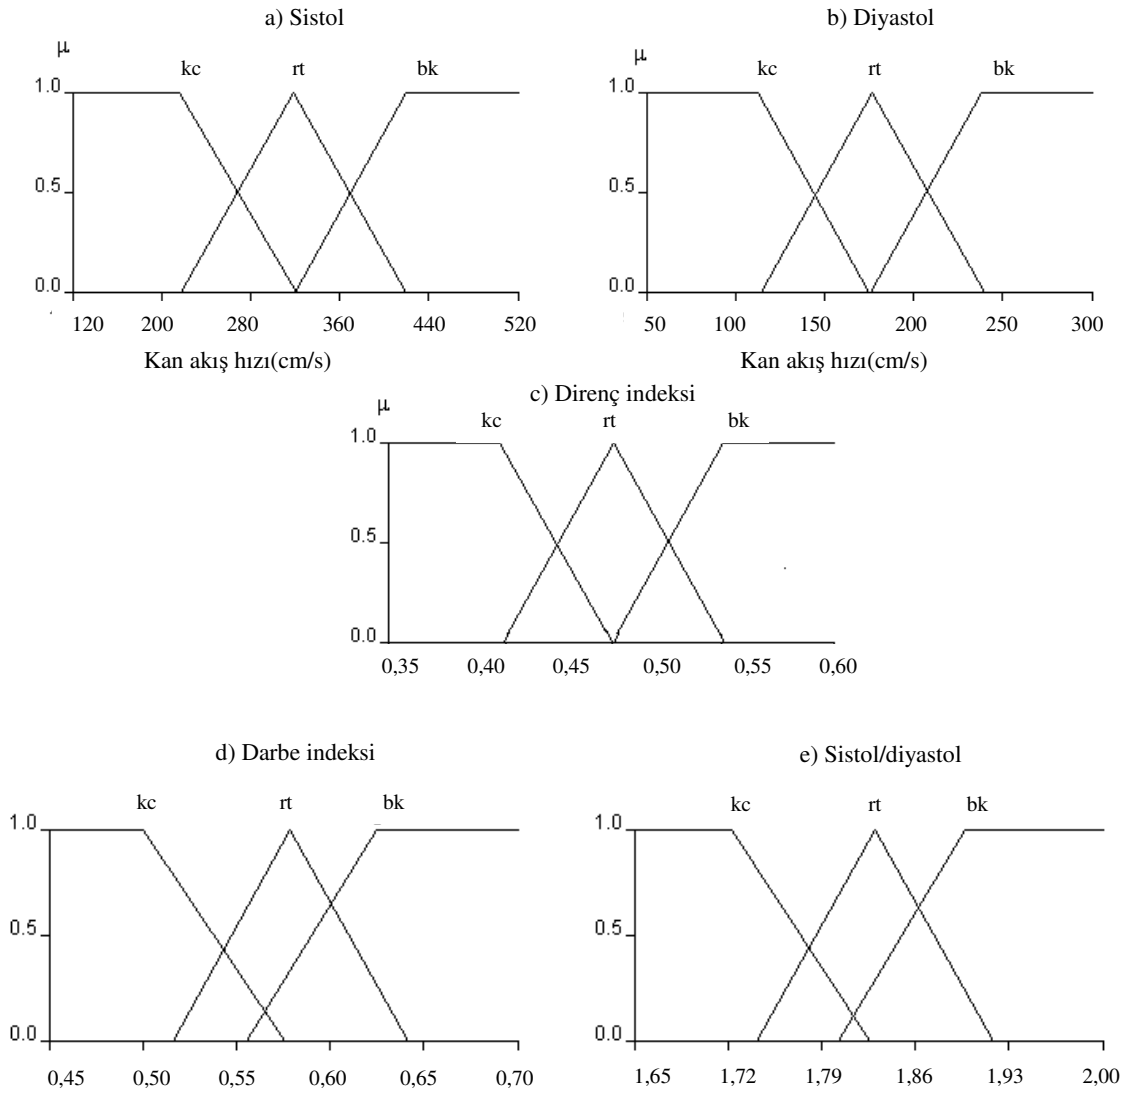
Çizelge 3.4. İstatistiksel sonuçlar

İstatistik tipi	Aort kapakçığı	Mitral kapakçık
Belirlilik	% 100	% 95
Duyarlılık	% 95	% 93,33
Doğru sınıflama	% 96,67	% 93,33

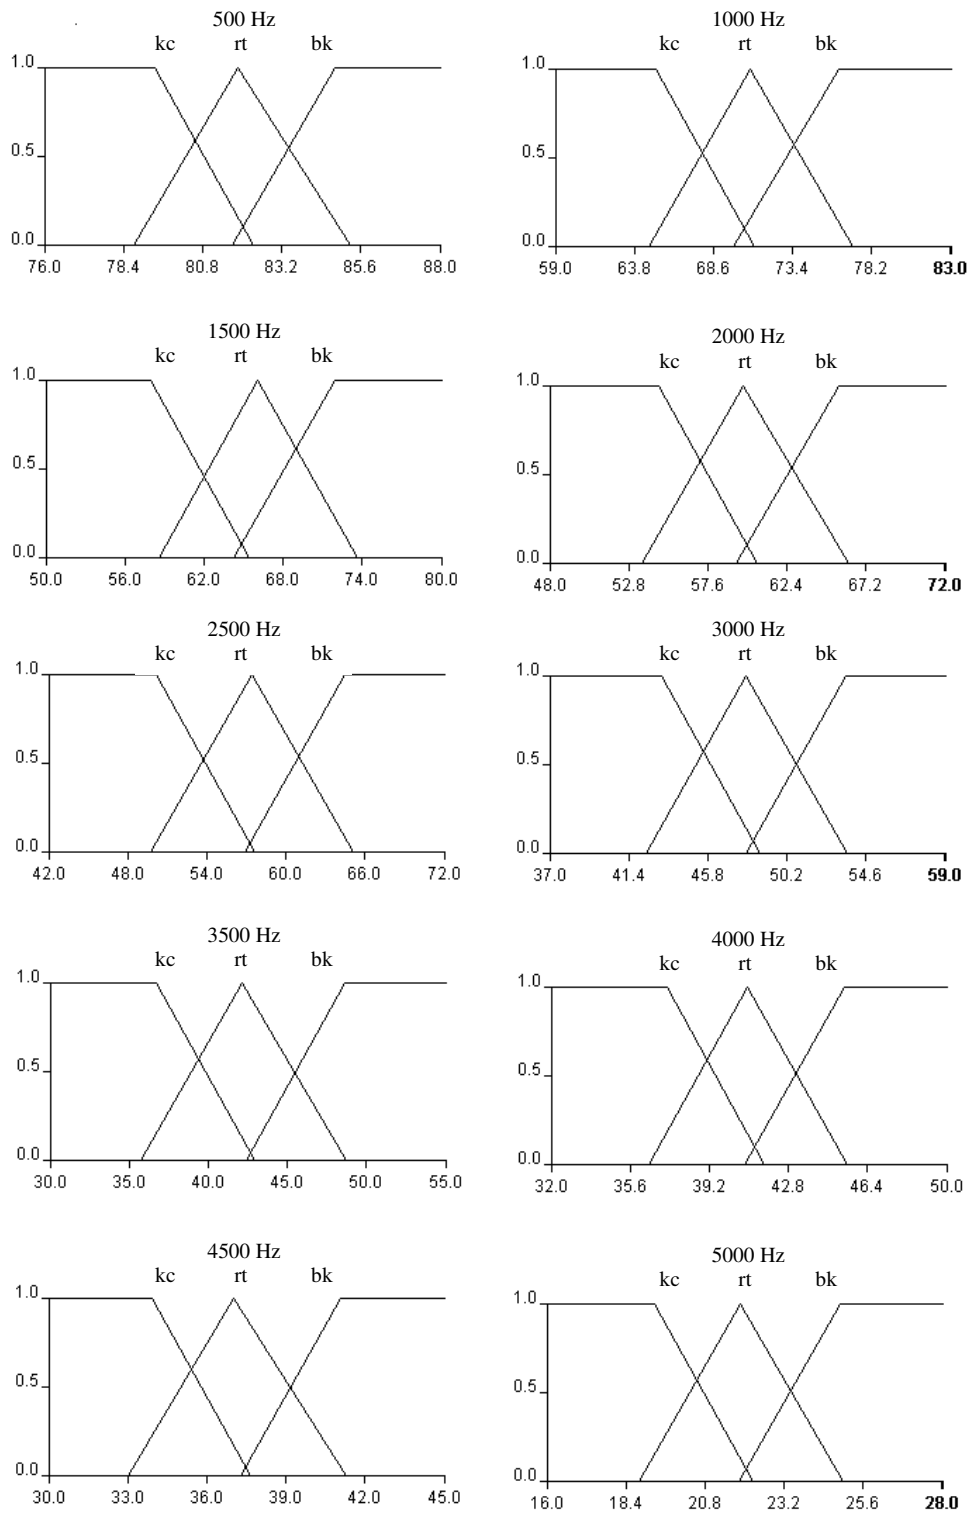
Çok katmanlı algılayıcı'nın tahmin kabiliyetini göstermek için test sonucu çıkış verileri analiz edilerek ROC eğrisi ortaya çıkarılır. Ayrıca ROC eğrisi altında kalan alan da hesaplanarak sinir ağının performansı ölçülebilir. Bu değer 1'e ne kadar yakınsa, çalışma o oranda başarılı demektir. Aort kapakçığı çalışmasında ROC eğrisi altında kalan alan 0,928, mitral kapakçık çalışmasında ise 0,905 olarak bulunmuştur. Bu da her iki çalışmanın başarılı olduğunu göstermektedir.

3.4. Kardiyak Doppler İşaretlerinin NEFCLASS ile Sınıflandırılması

Bu çalışmada da, aort ve mitral kapakçık olmak üzere iki ayrı uygulama gerçekleştirilmiştir. Kaydedilen kardiyak Doppler verilerinin uzman doktor tarafından MR (Manyetik Rezonans) görüntüleme ile incelenmesi sonucunda, her bir kapakçık için, 20 tanesinin yetmezlik (Sınıf 1), 20 tanesinin darlık (Sınıf 2) ve diğer 20 tanesinin ise normal (Sınıf 3) olduğu teşhis edilmiştir. Bu verilerin 30 tanesi eğitim için (10 yetmezlik, 10 darlık ve 10 normal), geri kalan 30 tanesi de test için kullanılarak NEFCLASS sinirsel bulanık sınıflayıcıya uygulanmıştır. Sistemde, çıkış tahminini en iyi yaklaşımla yakalayabilmek için üçgen üyelik fonksiyonu kullanılmış ve her bir boyutta bulanık kuralları değerlendirmek için 3 küme kullanılmıştır. Üyelik fonksiyonları küçük (kc), orta (rt), büyük (bk) şeklinde etiketlenmiştir. Çalışmalar sonucunda elde edilen bulanık kümeler Şekil 3.13 ve 3.14'de verilmiştir. Toplama fonksiyonu (aggregation function) olarak maximum kullanılmış ve üyelik fonksiyonlarının en iyi şekilde eğitilmesi için öğrenme hızı 0,01 alınmıştır.



Şekil 3.13. Bulanık kümeler (Aort kapakçığı)



Şekil 3.14. Bulanık kümeler (Mitril kapakçık)

Şekil 3.13'te aort kapakçığındaki kan akışlarının sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı değerlerine ait bulanık kümeler görülmektedir. Her bir değişken üç kümeye bölünmüştür. Örneğin, sistol değişkeninde küçük bulanık kümesi 120-320 cm/s arasında, orta bulanık kümesi 220-420 cm/s arasında ve büyük bulanık kümesi 320-520 cm/s arasındadır.

Şekil 3.14'te ise mitral kapakçığındaki kan akışlarının güç spektrum yoğunluğu analizlerinde 500-5000 Hz arasındaki değerlere ait bulanık kümeler görülmektedir. Her bir değişken üç kümeye bölünmüştür. Örneğin, 500 Hz değişkeninde küçük bulanık kümesi 76-82 dB arasında, orta bulanık kümesi 79-85 dB arasında ve büyük bulanık kümesi 81-88 dB arasındadır.

Aort kapakçığından kaydedilen kardiyak Doppler işaretlerinin HFD analizi sonucunda elde edilen verilerin %50'si eğitim, %50'si de test için kullanıldığında; 200 adım sonucu oluşan sınıflamada, bulanık kural sayısı 5, sınıflama başarısı ise %91,67 olarak elde edilmiştir. 500 adım sonucu sınıflamada ise bulanık kural sayısı 5 (Çizelge 3.5), sınıflama başarısı %95'dir. Bu çalışmalar Çizelge 3.6'da ayrıntılı olarak sunulmuştur.

Elde edilen kural tabanında aort yetmezliği için 1, aort darlığı ve normaller için ise 2 kural bulunmaktadır. 200 adımdan sonra, adım sayısı 500'e arttırıldığında, test işleminde başarı oranının %6,36 arttığı tespit edilmiştir. Sınıflama 1000 adım için de tekrarlanmış, fakat sınıflama başarısı değişmemiştir.

NEFCLASS sinirsel bulanık sınıflayıcının, sınıflamadaki performansını arttırmak için, bulanık kurallara ve giriş değişkenlerine budama işlemi uygulanırsa; 200 adımda bulanık kural sayısı 3, sınıflama başarısı %95, 500 adımda ise bulanık kural sayısı 3 (Çizelge 3.7), sınıflama başarısı %96,67 olarak elde edilmiştir. Budama işleminden sonraki sınıflamaya ait değerler Çizelge 3.8'de verilmiştir.

Çizelge 3.5. 500 adımdaki kurallar (Aort kapakçığı)

R1 : Eğer (Sistol kc ise ve Diyastol bk ise ve Direnç indeksi kc ise ve Darbe indeksi kc ise ve Sistol/diyastol oranı kc ise) Sınıf 1 (aort yetmezliği)

R2 : Eğer (Sistol rt ise ve Diyastol rt ise ve Direnç indeksi rt ise ve Darbe indeksi kc ise ve Sistol/diyastol oranı kc ise) Sınıf 2 (aort darlığı)

R3 : Eğer (Sistol kc ise ve Diyastol rt ise ve Direnç indeksi rt ise ve Darbe indeksi kc ise ve Sistol/diyastol oranı kc ise) Sınıf 2

R4 : Eğer (Sistol kc ise ve Diyastol kc ise ve Direnç indeksi bk ise ve Darbe indeksi rt ise ve Sistol/diyastol oranı rt ise) Sınıf 3 (normal)

R5 : Eğer (Sistol kc ise ve Diyastol kc ise ve Direnç indeksi bk ise ve Darbe indeksi bk ise ve Sistol/diyastol oranı bk ise) Sınıf 3

Çizelge 3.6. Sinirsel bulanık sınıflamaya ait değerler (Aort kapakçığı)

<i>Adım</i>	<i>Kural</i>	<i>Eğitim</i>	<i>Test</i>	<i>Toplam</i>
<i>Değeri</i>	<i>Sayısı</i>			
200	5	%96,67	%86,67	%91,67
500	5	%96,67	%93,33	%95

Çizelge 3.7. 500 adımda budamadan sonraki kurallar (Aort kapakçığı)

R1 : Eğer (Diyastol bk ise) Sınıf 1

R2 : Eğer (Diyastol kc ise) Sınıf 2

R3 : Eğer (Diyastol rt ise) Sınıf 3

Çizelge 3.8. Sinirsel bulanık sınıflamaya ait değerler (Budama işleminden sonra, Aort kapakçığı)

<i>Adım Değeri</i>	<i>Kural Sayısı</i>	<i>Eğitim</i>	<i>Test</i>	<i>Toplam</i>
200	3	%96,67	%93,33	%95
500	3	%96,67	%96,67	%96,67

Çizelge 3.6'daki budama öncesi ve Çizelge 3.8'deki budama sonrası performansları karşılaştırıldığında, budama işleminden sonra 200 adımda bulanık kural sayısının 5'ten 3'e düştüğü, başarı oranının ise %91,67' den %95'e çıktığı, yani % 3,33 arttığı tespit edilmiştir. Ayrıca kurallardaki değişken sayısı da azaltılarak daha anlaşılabilir kural tabanı elde edilmiştir (64, 65).

Mitral kapakçıktan kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu analizi sonuçları elde edilen veriler kullanıldığında; 500 adım sonucu oluşan sınıflamada, bulanık kural sayısı 11, sınıflama başarısı ise %85 olarak elde edilmiştir. 1000 adım sonucu sınıflamada ise bulanık kural sayısı 12 (Çizelge 3.9), sınıflama başarısı %86,67'dir. Bu çalışmalar Çizelge 3.10'da ayrıntılı olarak sunulmuştur.

Çizelge 3.9'daki kural tabanından da görüleceği gibi, mitral yetmezliği ve darlık için 3'er kural, normal kişiler için ise 6 kural elde edilmiştir. Bu da sağlıklı kişilerin mitral kapakçığından kaydedilen işaretlerin güç spektrum yoğunluğundan elde edilen parametrelerin daha zor sınıflandırıldığını göstermektedir. 500 adımdan sonra, adım sayısı 1000'e arttırıldığında test verisinin sınıflamadaki başarı oranının % 3,34 arttığı tespit edilmiştir. Sınıflama 2000 adım için de tekrarlanmış, fakat sınıflama başarısı değişmemiştir.

Çizelge 3.9. 1000 adımdaki kurallar (Mitral kapakçık)

1.Eğer (500 Hz rt ise ve 1000 Hz bk ise ve 1500 Hz bk ise ve 2000 Hz bk ise ve 2500 Hz rt ise ve 3000 Hz bk ise ve 3500 Hz bk ise ve 4000 Hz bk ise ve 4500 Hz bk ise ve 5000 Hz bk ise) Sınıf 1 (Mitral yetmezliği)
2.Eğer (500 Hz kc ise ve 1000 Hz bk ise ve 1500 Hz bk ise ve 2000 Hz bk ise ve 2500 Hz rt ise ve 3000 Hz bk ise ve 3500 Hz bk ise ve 4000 Hz bk ise ve 4500 Hz bk ise ve 5000 Hz bk ise) Sınıf 1
3.Eğer (500 Hz kc ise ve 1000 Hz bk ise ve 1500 Hz rt ise ve 2000 Hz rt ise ve 2500 Hz kc ise ve 3000 Hz rt ise ve 3500 Hz rt ise ve 4000 Hz kc ise ve 4500 Hz rt ise ve 5000 Hz kc ise) Sınıf 1
4.Eğer (500 Hz kc ise ve 1000 Hz bk ise ve 1500 Hz rt ise ve 2000 Hz rt ise ve 2500 Hz kc ise ve 3000 Hz kc ise ve 3500 Hz kc ise ve 4000 Hz kc ise ve 4500 Hz rt ise ve 5000 Hz kc ise) Sınıf 2 (Mitral darlığı)
5.Eğer (500 Hz kc ise ve 1000 Hz bk ise ve 1500 Hz rt ise ve 2000 Hz kc ise ve 2500 Hz kc ise ve 3000 Hz kc ise ve 3500 Hz kc ise ve 4000 Hz kc ise ve 4500 Hz rt ise ve 5000 Hz kc ise) Sınıf 2
6.Eğer (500 Hz bk ise ve 1000 Hz bk ise ve 1500 Hz rt ise ve 2000 Hz rt ise ve 2500 Hz kc ise ve 3000 Hz kc ise ve 3500 Hz kc ise ve 4000 Hz kc ise ve 4500 Hz kc ise ve 5000 Hz kc ise) Sınıf 2
7.Eğer (500 Hz kc ise ve 1000 Hz bk ise ve 1500 Hz bk ise ve 2000 Hz bk ise ve 2500 Hz bk ise ve 3000 Hz kc ise ve 3500 Hz kc ise ve 4000 Hz kc ise ve 4500 Hz kc ise ve 5000 Hz rt ise) Sınıf 3 (Normal)
8.Eğer (500 Hz rt ise ve 1000 Hz bk ise ve 1500 Hz kc ise ve 2000 Hz bk ise ve 2500 Hz rt ise ve 3000 Hz kc ise ve 3500 Hz kc ise ve 4000 Hz kc ise ve 4500 Hz kc ise ve 5000 Hz kc ise) Sınıf 3
9.Eğer (500 Hz bk ise ve 1000 Hz bk ise ve 1500 Hz bk ise ve 2000 Hz rt ise ve 2500 Hz rt ise ve 3000 Hz kc ise ve 3500 Hz rt ise ve 4000 Hz kc ise ve 4500 Hz rt ise ve 5000 Hz bk ise) Sınıf 3
10.Eğer (500 Hz bk ise ve 1000 Hz kc ise ve 1500 Hz kc ise ve 2000 Hz kc ise ve 2500 Hz kc ise ve 3000 Hz kc ise ve 3500 Hz kc ise ve 4000 Hz kc ise ve 4500 Hz kc ise ve 5000 Hz bk ise) Sınıf 3
11.Eğer (500 Hz bk ise ve 1000 Hz bk ise ve 1500 Hz bk ise ve 2000 Hz bk ise ve 2500 Hz bk ise ve 3000 Hz rt ise ve 3500 Hz rt ise ve 4000 Hz kc ise ve 4500 Hz rt ise ve 5000 Hz bk ise) Sınıf 3
12.Eğer (500 Hz bk ise ve 1000 Hz bk ise ve 1500 Hz bk ise ve 2000 Hz kc ise ve 2500 Hz rt ise ve 3000 Hz rt ise ve 3500 Hz rt ise ve 4000 Hz rt ise ve 4500 Hz rt ise ve 5000 Hz bk ise) Sınıf 3

Çizelge 3.10. Sinirsel bulanık sınıflamaya ait değerler (Mitral kapakçık)

<i>Adım</i>	<i>Kural</i>	<i>Eğitim</i>	<i>Test</i>	<i>Toplam</i>
<i>Değeri</i>	<i>Sayısı</i>			
500	11	%96,67	%73,33	%85
1000	12	%96,67	%76,67	%86,67

NEFCLASS sinirsel bulanık sınıflayıcının mitral kapakçık hastalıklarını sınıflamadaki performansını arttırmak için, bulanık kurallara ve giriş değişkenlerine budama işlemi uygulanırsa; 500 adımda bulanık kural sayısı 5, sınıflama başarısı %86,67, 1000 adımda ise bulanık kural sayısı 7 (Çizelge 3.11), sınıflama başarısı %90 olarak elde edilmiştir. Budama işleminden sonraki sınıflamaya ait değerler Çizelge 3.12'de verilmiştir.

Çizelge 3.11. 1000 adımda budamadan sonraki kurallar (Mitral kapakçık)

1. Eğer (500 Hz <i>rt</i> ise ve 1000 Hz <i>bk</i> ise ve 3000 Hz <i>bk</i> ise ve 3500 Hz <i>bk</i> ise ve 4000 Hz <i>bk</i> ise ve 4500 Hz <i>bk</i> ise) Sınıf 1
2. Eğer (500 Hz <i>kc</i> ise ve 1000 Hz <i>bk</i> ise ve 3000 Hz <i>bk</i> ise ve 3500 Hz <i>bk</i> ise ve 4000 Hz <i>bk</i> ise ve 4500 Hz <i>bk</i> ise) Sınıf 1
3. Eğer (500 Hz <i>kc</i> ise ve 1000 Hz <i>bk</i> ise ve 3500 Hz <i>rt</i> ise) Sınıf 1
4. Eğer (500 Hz <i>kc</i> ise ve 1000 Hz <i>bk</i> ise ve 3000 Hz <i>kc</i> ise ve 3500 Hz <i>kc</i> ise) Sınıf 2
5. Eğer (500 Hz <i>bk</i> ise ve 1000 Hz <i>bk</i> ise ve 3000 Hz <i>kc</i> ise ve 3500 Hz <i>kc</i> ise ve 4500 Hz <i>kc</i> ise) Sınıf 2
6. Eğer (500 Hz <i>bk</i> ise ve 1000 Hz <i>kc</i> ise ve 3000 Hz <i>kc</i> ise ve 3500 Hz <i>kc</i> ise ve 4500 Hz <i>kc</i> ise) Sınıf 3
7. Eğer (500 Hz <i>bk</i> ise ve 1000 Hz <i>bk</i> ise ve 3500 Hz <i>rt</i> ise) Sınıf 3

Çizelge 3.12. Sinirsel bulanık sınıflamaya ait değerler (Budama işleminden sonra, Mitral kapakçık)

<i>Adım</i>	<i>Kural</i>	<i>Eğitim datası</i>	<i>Test datası</i>	<i>Toplam data</i>
<i>Değeri</i>	<i>Sayısı</i>			
500	5	%93,33	%80	%86,67
1000	7	%93,33	%86,67	%90

Çizelge 3.11’de görüldüğü gibi, budama işleminden sonra 1000 adımda 3 mitral yetmezliği ve 2’şer mitral darlığı ve normal olmak üzere toplam 7 kural elde edilmiştir. Çizelge 3.12’de ise başarı oranının budama işleminden sonra %86,67’ den %90’a çıktığı, yani % 3,33 arttığı görülmektedir (66).

Aort kapakçığından kaydedilen işaretlerin HFD analizinden elde edilen parametrelerle yapılan sınıflamada, mitral kapakçıktan kaydedilen işaretlerin güç spektrum yoğunluğu eğrilerinden elde edilen parametrelerle yapılan sınıflamaya göre daha az sayıda kural elde edilmiştir. Ayrıca aort çalışmasında giriş parametre sayısı daha az olduğundan, uzman hekim daha kolay bir şekilde sınıflayıcının teşhis sonucunu yorumlayabilmiştir.

3.5. İrdeleme

Bu çalışmada, aort kapakçığından elde edilen işaretlerin, HFD analizi sonucunda bulunan; sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı değerlerinin çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcı ile yapılan sınıflama çalışmalarında % 96,67 doğru sınıflama başarısı elde edilmiştir. Çok katmanlı algılayıcı sinir ağı, kara kutu olarak düşünüldüğünden, kullanıcıya sadece sınıflama sonucunu vermektedir. NEFCLASS sinirsel bulanık sınıflayıcıda ise bulanık kümeler ve kurallar yardımıyla, hastalık teşhisi daha anlaşılır ve yorumlanabilir hale getirilmektedir.

Bu çalışmada ayrıca, 60 kişinin mitral kapakçığından kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu eğrileri elde edilmiştir. Elde edilen eğrilerden 500’er Hz’lik artışlara karşılık gelen güç spektrum yoğunluğu değerleri çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcıya giriş vektörü olarak uygulanmış ve mitral yetmezliği, mitral darlığı veya normal olduğuna ilişkin sınıflamalar yapılmıştır. Bu sınıflamalar sonucunda, çok katmanlı algılayıcı sinir ağı ile %93,33, NEFCLASS sinirsel bulanık sınıflayıcı ile de, %90 başarı oranı elde edilmiştir. Sınıflama başarısı çok katmanlı algılayıcı sinir ağında daha yüksek olmasına rağmen, NEFCLASS sinirsel bulanık sınıflayıcıda teşhis sonuçlarının

anlaşılabilirliği daha fazladır. Sinirsel bulanık sınıflayıcılarda, bulanık kümeler ve kurallar sayesinde yorumlanabilirlik ön plana çıkmaktadır.

Aort yetmezliği ve darlığının sınıflandırıldığı, sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı değerlerinin giriş vektörü olarak kullanıldığı çalışmada, mitral yetmezliği ve darlığının sınıflandırıldığı, güç spektrum yoğunluğu değerlerinin (toplam 10 tane) giriş vektörü olarak kullanıldığı çalışmaya göre daha yüksek başarı oranı yakalanmıştır.

NEFCLASS sinirsel bulanık sınıflayıcı ile elde edilen sonuçlar, bulanık sınıflayıcıların hastalık teşhisinde kullanılabilecek önemli bir araç olduğunu göstermektedir. NEFCLASS sinirsel bulanık sınıflayıcının amacı, bulanık kümeler yardımıyla, dilsel terimlerle yorumlanabilen kuralların elde edilmesidir. Sinirsel bulanık sınıflayıcı bazı hastaların hastalık teşhisini yapmak için kullanıldığında, kurallardaki dilsel terimlerden dolayı, hem hekim, hem de hasta için bulunan teşhisin anlaşılabilirliği diğer sistemlere göre daha fazla olmaktadır.

Yapılan sınıflamalar sonucunda; NEFCLASS sinirsel bulanık sınıflayıcı ve çok katmanlı algılayıcı sinir ağının kardiyak Doppler işaretlerinin sınıflandırılmasında başarılı olduğu gözlenmiştir. Ancak kullanılan sistemlerin gerçek zamanda çalışmayışı, pratik olarak kullanım sahasını daraltmaktadır.

NEFCLASS sinirsel bulanık sınıflayıcı ile bulunan teşhis sonucu, hekim ve hasta için tamamen açık ve anlaşılırdır. Sinirsel bulanık sınıflayıcının kuralları, hastaya teşhisi açıklamak için kullanılabilir. Kural tabanlı olmayan sınıflayıcılar çıkışın sadece hangi olasılıkta olacağını hesaplarlar, teşhisin sezgisel olarak açıklanmasını sağlayamazlar. Bulanık sınıflayıcıdan elde edilen bilgi, bu konuda bilgisi olmayan kişiler tarafından bile kolaylıkla anlaşılabilir. Sinirsel bulanık sınıflayıcı olasılık bilgisi sağlamaz, önceden eğitilip düzenlenmiş bulanık kümeler ve aktif olan birkaç kural vasıtasıyla, sonuç bilgisinin anlaşılabilir olmasını sağlar.

Teşhis sonucunun anlaşılır, yorumlanabilmesini arttırmak için, NEFCLASS sinirsel bulanık sınıflayıcı ile elde edilen kurallara budama işlemi yapılmaktadır. Bu sayede teşhisin bulunmasında daha etkili olan kurallar kalmakta, diğerleri silinmektedir. Ayrıca sistemin girişine verilen giriş değişkenlerinin de teşhisin bulunmasına olan etkisi incelenmekte, etkisi az olan veya hiç olmayan değişkenlerde kurallardan silinmekte, böylece daha kısa ve daha anlaşılır kurallar elde edilmektedir.

4. SONUÇ

Günümüzde bir çok etkene bağlı olarak kalp kapaklarının fonksiyonlarında bozukluklara sık sık rastlanmaktadır. Bu bozukluklar daralma veya yetmezlik şeklinde ortaya çıkmakta ve kan akışında düzensizliğe sebep olmaktadır. Buna bağlı olarak ta çeşitli hastalıklar, kişilerin yaşamını olumsuz bir şekilde etkilemektedir. Ultrasonik Doppler tekniği, hastaların kalp kapaklarındaki kan akışını inceleyerek, hastaya cerrahi bir müdahale yapmadan, daralma ve yetmezliği teşhis edebilmeyi sağlamaktadır.

Kalp kapaklarından elde edilen Doppler işaretleri, çeşitli spektrum analiz metotları ile analiz edilerek Doppler spektrumunun zamanla değişimini gösteren sonogramlar ve bu sonogramlardan da kalp kapaklarındaki kan akışı ile ilgili çeşitli klinik bilgiler elde edilebilmektedir.

Çeşitli hastalar üzerinde yapılan bu çalışmada, aort kapakçığında meydana gelen daralmaların ve yetmezliğin kan akışını nasıl etkilediği incelenmiştir. Bu hastalardan elde edilen Doppler işaretleri, HFD analiz yöntemine uygulanarak HFD parametreleri elde edilmiş, daha sonra bu parametrelerden sistol, diyastol, direnç indeksi, darbe indeksi ve sistol/diyastol oranı değerleri bulunmuştur. Bu değerler de çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcı ile sınıflandırılmıştır.

HFD ve benzeri klasik spektral analiz metotları çerçeve süresinin büyük olduğu durumlarda uzman hekim için teşhise yönelik yeterli sonuçlar vermektedir. Ancak yüksek hızlı, çalkantılı (türbülans) veya tıkanıklık sonrası bölgelerdeki akışlarda HFD metodunun performansı oldukça düşmekte, spektrumda genişleme ve frekans seçiciliğinde azalma gözlenmektedir. Bu nedenlerden dolayı, HFD'nin performansını ve doğruluğunu arttırmak için; HFD sonucu elde edilen sistol, diyastol ve bunlara bağlı parametre değerleri, çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcı ile sınıflandırılmıştır. Bu sınıflamalar sonucunda, uzman hekimin

hastalık teşhisine ait olabilecek yanlışları en aza indirilmiş ve daha hızlı teşhis süreci sağlanmıştır.

Bu çalışmada, 60 kişinin aort kapakçığından kaydedilen kardiyak Doppler işaretleri HFD ile işlenerek sistol, diyastol değerleri ve bunlara bağlı olarak direnç indeksi, darbe indeksi ve Sistol/diyastol değerleri elde edilmiştir. Bu değerler çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcıya giriş vektörü olarak uygulanmış ve teşhisin aort yetmezliği, aort darlığı veya normal olduğuna ilişkin sınıflamalar yapılmıştır. Yapılan sınıflamalar sonucunda her iki sistem ile de %96,67 başarı oranı gerçekleştirilmiştir.

Bu çalışmada, ayrıca mitral yetmezliği, mitral darlığı ve sağlıklı olan toplam 60 hastanın mitral kapakçığından kaydedilen kardiyak Doppler işaretlerinin güç spektrum yoğunluğu analizleri yapılarak, her hastaya ait güç spektrum yoğunluğu eğrileri elde edilmiştir. Güç spektrum yoğunluğu analizi sonucu elde edilen eğrilerden 500'er Hz'lik artışlara karşılık gelen güç spektrum yoğunluğu değerleri (toplam 10 tane) çok katmanlı algılayıcı sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcıya giriş vektörü olarak uygulanmıştır. Yapılan sınıflamalarda, çok katmanlı algılayıcı sinir ağı ile %93,33, NEFCLASS sinirsel bulanık sınıflayıcı ile de %90 oranında doğru sınıflama başarısı elde edilmiştir.

NEFCLASS sinirsel bulanık sınıflayıcı ve çok katmanlı algılayıcı sinir ağı ile elde edilen sonuçlar, bu sistemlerin kardiyak Doppler işaretlerinin hastalık teşhisinin yapılması amacıyla kullanılabilmesini göstermektedir.

Bu çalışmada yalnızca aort ve mitral kapakçıktan alınan işaretlerden elde edilen parametrelerle sinir ağı ve NEFCLASS sinirsel bulanık sınıflayıcı eğitilmiştir ve hastanın kapakçığında, darlık veya yetmezlik olup olmadığı tahmin edilmeye çalışılmıştır. Bundan sonraki çalışmalarda kardiyak Doppler işaretlerinden daha iyi özellikler çıkartabilecek spektral analiz yöntemleriyle beraber, sinir ağı, bulanık sistem ve genetik algoritmanın beraber kullanıldığı farklı sistemler ile çalışılarak, hangi yöntem ve modellerin daha verimli olabileceği incelenmelidir.

KAYNAKLAR

1. Satomura, S., "Study of flow patterns in peripheral arteries by ultrasonics", *Journal of Acoustical Society of Japan*, 15: 151 – 158 (1959).
2. Edler, I., "Early Echocardiography", *Ultrasound in Medicine and Biology*, 17 (5): 425–431 (1991).
3. Hertz, C.H., "The interaction of physicians, physicists and industry in the development of echocard.", *Ultrasound in Medicine and Biology*, 1 (1): 3 – 11 (1973).
4. Hatle, L., Angelsen, B., "Doppler ultrasound in cardiology. Physical and clinical applications", 2nd edn, *Lea and Febiger*, Philadelphia, 81 – 85 (1982).
5. Zadeh, L.A., "Fuzzy sets", *Information and Control*, 8: 338-353 (1965).
6. Zadeh, L.A., "Biological application of the theory of fuzzy sets and systems", *Proc. Int. Sym. on Biocybernetics of the Central Nervous System*, Boston, 199-212 (1969).
7. Kalmanson, D., Stegall, H.F., "Cardiovascular investigations and fuzzy set theory", *American Journal of Cardiology*, 35: 80-84 (1975).
8. Joly, H., "Application of fuzzy set theory to the evaluation of cardiac functions", *Proc. 3rd World Conf. On Medical Information*, Tokyo, 91-95 (1980).
9. Degani, R., Bortolan, G., "Fuzzy decision-making in electrocardiography", *Artificial Intelligence in Medicine*, 1 (2): 87-91 (1989).
10. Kere, E.E., "Outline of an expert system for ECG diagnosis using fuzzy sets", *Artificial Intelligence in Medicine*, 1 (3): 139-144 (1989).
11. Hudson, DL., Cohen, ME., Deedwania, PC., "A hybrid system for diagnosis and treatment of heart disease", *Proc. 16th Annual Int. Conf. of the IEEE Engineering in Medicine Biology Society*, New York, 1368-1369 (1994).
12. Akay, YM., Akay, M., Welkowitz, W., Kostis, J., "Noninvasive detection of coronary artery disease", *IEEE Engineering in Medicine and Biology Magazine*, 13 (5): 761-764 (1994).
13. Cios, K.J., Goodenday, L.S., Shah, K.K., Serpen G., "A novel algorithm for classification of SPECT images of a human heart", *Proc. 9th IEEE Symp. on computer-based medical systems*, Los Alamitos, 1-5 (1996).

14. Jain, R., Mazumdar, J., Moran, W., "Application of fuzzy classifier system to coronary artery disease and breast cancer", *Australasian Physical & Engineering Sciences in Medicine*, 21 (3): 141-147 (1998).
15. Nauck, D., Kruse, R., "Obtaining interpretable fuzzy classification rules from medical data", *Artificial Intelligence in Medicine*, 16: 149-169 (1999).
16. Güler, İ., Hardalaç, F., Barışçı, N., "Application of FFT analyzed Cardiac Doppler Signals To Fuzzy Algorithm", *Computers in Biology and Medicine*, 32: 435-444 (2002).
17. Güler, İ., Hardalaç, F., Ergun, U., Barışçı, N., "Classification of Aorta Doppler signals using variable coded-hierarchical genetic fuzzy system", *Expert Systems with Applications*, 26: 321-333 (2004).
18. Guyton, A.C., "Textbook of medical physiology", *Sounders Company*, 251-333 (1986).
19. Cameron, J.R., Skofronick, J.G., Grant, R.M., "Physics of the Body", *Medical Physics Publishing*, Wisconsin, 253-300 (1999).
20. Ghista, D.N., "Advances in Cardiovascular Physics", *Karger*, New York, 286-309 (1989).
21. Glass, L., Hunter, P., McCulloch, A., "Theory of heart: Biomechanics, Biophysics and nonlinear dynamics of cardiac function", *Springer-Verlag*, New York, 137-161 (1991).
22. McDonald, DA, "Blood flow in arteries", *Edward Arnold*, London, 55-70 (1974).
23. Hobbie, R.K., "Intermediate Physics for medicine and biology", 3rd edition, *Springer-Verlag*, New York, 312-347 (1997).
24. Kenner, T., "Cardiovascular System Dynamics: Models & Measurements", *Plenum*, New York, 82-108 (1982).
25. Evans, D.H., McDicken, W.N., Skidmore, R., Woodcock, J.P., "Doppler Ultrasound Physics, Instrumentation and Clinical Applications", *John Wiley & Sons*, 85-112 (1989).
26. Frederick, W.K., "Doppler Ultrasound Principles and Instruments", *W. B. Saunders Company*, Philadelphia, 134-157 (1990).
27. Raymond, L.P., Robert A.S., "Practical Doppler Ultrasound for the Clinician", *Williams & Wilkins*, Baltimore, 50-63 (1991).

28. White, D.N., "Johann Christian Doppler and his effect – A brief history", *Ultrasound in Medicine and Biology*, 8: 583-591 (1982).
29. Kay, S.M., Marple, S.L., "Spectrum analysis- A modern perspective", *Proc. IEEE*, 69: 1380-1419 (1981).
30. Güler, İ., Kara, S., Güler, N.F., Kıymık, M.K., "Application of AR and FFT spectral analysis to Tricuspid and Mitral valve stenosis", *Computer Methods & Programs in Biomedicine*, 49: 29-36 (1996).
31. Güler, İ., Hardalaç, F., Müldür, S., "Determination of aorta failure with the application of FFT, AR and wavelet methods to Doppler technique", *Computers in Biology and Medicine*, 31: 229-238 (2001).
32. Franklin, D.L., Schlegel, W.A., Watson, N.W., "Ultrasonic Doppler shift blood flowmeter: Circuitry and practical applications", *Biomedical Science Instrumentation*, 1: 301-309 (1963).
33. Schlindwein, F.S., Smith, M.J., Evans, D.H., "Spectral analysis of Doppler signals and computation of the normalised first moment in real time using a digital signal processor", *Medical & Biological Engineering Computing*, 26: 228-232 (1988).
34. Larry, Y.L., Richard, S.C., "A nonstationary signal simulation model for continuous wave and pulsed Doppler ultrasound", *IEEE Transactions On Ultrasonics Ferroelectrics and Frequency Control*, 21: 522-530 (1989).
35. Kaluzynski, K., "Analysis of application possibilities of autoregressive modeling to Doppler blood flow signal spectral analysis", *Medical & Biological Engineering Computing*, 25: 373-376 (1987).
36. Schlindwein, F.S., Evans, D.H., "A real time autoregressive spectrum analyzer for Doppler ultrasound signals", *Ultrasound in Medicine and Biology*, 15: 263-272 (1989).
37. Vaitkus, P.J., Cobbold, R.S.C., Johnston, K.W., "A comparative study and assessment of Doppler ultrasound spectral estimation techniques Part 1: Estimation methods", *Ultrasound in Medicine and Biology*, 14: 661-672 (1988).
38. Vaitkus, P.J., Cobbold, R.S.C., Johnston, K.W., "A comparative study and assessment of Doppler ultrasound spectral estimation techniques Part 2: Methods and results", *Ultrasound in Medicine and Biology*, 14: 673-688 (1988).
39. Kaluzynski, K., "Order selection in Doppler blood flow signal spectral analysis using autoregressive modeling", *Medical & Biological Engineering Computing*, 25: 373-376 (1988).

40. Baykal, N., Reggia, J.A., Yalabik, N., Erkmen, A., Beksac, M.S., "Feature discovery and classification of Doppler umbilical artery blood flow velocity waveforms", *Computers in Biology and Medicine*, 26: 451-462 (1996).
41. Hudson, D.L., Cohen, M.E., "Neural networks and artificial intelligence for biomedical engineering", *IEEE Press*, New York, 226-273 (2000).
42. Williams, R., "Neural network learning and application", *Addison-Wesley*, 78-137 (1989).
43. Anderson, J.A., Rosenfels, E., "Neurocomputing: Foundations of research", *MIT Press*, Cambridge, 147-185 (1998).
44. Hopfield, J.J., "Neural networks and physical systems with emergent collective computational abilities", *Proceedings of the National Academy of Sciences of The USA*, 79: 2554-2558 (1982).
45. Kohonen, T., "Self organization and associative memory", *Springer-Verlag*, Berlin, 93-139 (1988).
46. Rumelhart, D.E., McClelland, J.L., "Parallel distributed processing: Explorations in the microstructure of cognition", *MIT Press*, Cambridge, 165-187 (1986).
47. Grossberg, S., "Adaptive pattern classification and universal recoding: I. parallel development and coding of neural feature detectors", *Biological Cybernetics*, 23:121-134 (1976).
48. Zadeh, L.A., "Fuzzy Set and Applications", *Wiley Interscience Pub.*, New York, 54-82 (1987).
49. Lee, C.C., "Fuzzy Logic In Control Systems: Fuzzy Logic Controller – Part I", *IEEE Transactions on Systems Man and Cybernetics*, 20 (2): 404-418 (1990).
50. Barışçı, N., "Kardiyak Doppler sinyallerine hızlı Fourier dönüşümü analizi uygulayarak elde edilen sonuçların bulanık mantık ile değerlendirilmesi", *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Y. Lisans Tezi, Ankara, 10-25 (2000).
51. Bağcıoğulları, F., Bağcıoğulları, C.H., "Nesne Tanımlamada Yeni Bir Yaklaşım: Bulanık Kümeler", *Tübitak M.A.M.*, Kocaeli, 8-15 (1995).
52. Lee, C.C., "Fuzzy Logic In Control Systems: Fuzzy Logic Controller – Part II", *IEEE Transactions on Systems Man and Cybernetics*, 20 (2): 419-435 (1990).
53. Nauck, D., Klawonn, F., Kruse, R., "Foundations of neuro- fuzzy systems", *Wiley*, Chichester, 187-221 (1997).

54. Nauck, D., Kruse, R., “NEFCLASS-X: A soft computing tool to build readable fuzzy classifiers”, *BT Technology Journal*, 16 (3):180-190 (1998).
55. Nauck, D., Kruse, R., “NEFCLASS – A neuro fuzzy approach for the classification of data”, *Applied Computing 1995 ACM Symposium on Applied Computing*, New York, 461-465 (1995).
56. Nauck, D., Kruse, R., “A fuzzy neural approach learning fuzzy control rules and membership functions by fuzzy error backpropagation”, *Proc. IEEE Int. Conf. on Neural Networks*, San Francisco, 1022-1027 (1993).
57. Nauck, D., Kruse, R., “A neuro - fuzzy method to learn fuzzy classification rules from data”, *Fuzzy Sets and Systems*, 89: 277-288 (1997).
58. Nauck, U., “Design and implementation of a neuro – fuzzy data analysis tool in Java”, *Braunschweig Technical University*, M. S. Thesis, Braunschweig, Germany, 22-32 (1999).
59. Nauck, D., Kruse, R., “What are neuro – fuzzy classifiers”, *Proc. Seventh Int. Fuzzy systems Association World Congress IFSA’97*, Prague, 228–233 (1997).
60. Gürman, N.T., “Generation and improvement of fuzzy classifiers with incremental learning using fuzzyrulenet”, *Proc. 1995 ACM Symposium on Applied Computing*, New York, 466-470 (1995).
61. Berenji, H.R., Khedkar, P., “Clustering in product space for fuzzy inference”, *Proc. IEEE Int. Conf. on Neural Networks*, San Francisco, 1402-1407 (1993).
62. Sulzberger, S.M., Gürman, N.T., Vestli, S.J., “FUN: Optimization of fuzzy rule based systems using neural Networks”, *Proc. IEEE Int. Conf. on Neural Networks*, San Francisco, 1028-1035 (1993).
63. Buckley, J.J., Hayashi, Y., “Fuzzy neural networks: A survey”, *Fuzzy Sets and Systems*, 66:1-13 (1994).
64. Barışçı, N., Hardalaç, F., Güler, İ., “Aort Yetmezliği Ve Darlığının Sinirsel Bulanık Mantık Sistemi ile Sınıflandırılması”, *Biyomedikal Mühendisliği Ulusal Toplantısı Biyomut 2002*, İstanbul, 135–140 (2002).
65. Barışçı, N., Topal, E., Hardalaç, F., Güler, İ., “Classification of Aorta Insufficiency and Stenosis Using Neuro - Fuzzy System”, *Journal of Medical Systems*, 29 (2): 155-164 (2005).
66. Barışçı, N., Ergün, U., İlkay, E., Serhatlioğlu, S., Hardalaç, F., Güler, İ., “Classification of Mitral Insufficiency and Stenosis Using MLP Neural Network and Neuro - Fuzzy System”, *Journal of Medical Systems*, 28 (5): 423-436, 2004.

ÖZGEÇMİŞ

Necaattin Barışçı 1973 yılında Bulgaristan'ın Kırcaali kentinde doğdu. 1977 yılında ailesiyle birlikte İzmir'e göç etti. İlk, orta ve lise öğrenimini İzmir'de tamamladı. 1990 yılında Gazi Üniversitesi Teknik Eğitim Fakültesi, Elektronik – Bilgisayar Eğitimi Bölümüne girdi, 1994 yılında Bilgisayar Sistemleri Eğitimi Anabilim dalından mezun oldu.

1998 yılında Gazi Üniversitesi Fen Bilimleri Enstitüsü, Elektronik – Bilgisayar Eğitimi Anabilim dalında yüksek lisansa başladı. 1999'da Gazi Üniversitesi Teknik Eğitim Fakültesi, Bilgisayar Sistemleri Eğitimi Anabilim dalına Araştırma Görevlisi olarak girdi. 2000 yılında yüksek lisansı bitirip, aynı Anabilim dalında doktora programına başladı.

