T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KORONER ARTER HASTALIĞI VE LEZYON LOKALİZASYONU TAHMİNLERİNDE EFOR STRES TESTİNİN YAPAY ZEKA YÖNTEMLERİ İLE DEĞERLENDİRİLMESİ

İsmail BABAOĞLU

DOKTORA TEZİ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİMDALİ

Konya, 2010

ÖZET

DOKTORA TEZİ

KORONER ARTER HASTALIĞI VE LEZYON LOKALİZASYONU TAHMİNLERİNDE EFOR STRES TESTİNİN YAPAY ZEKA YÖNTEMLERİ İLE DEĞERLENDİRİLMESİ

İsmail BABAOĞLU

Selçuk Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Erkan ÜLKER

2010, 91 Sayfa

Jüri: Prof. Dr. Saadetdin HERDEM
Prof. Dr. Kurtuluş ÖZDEMİR
Yrd. Doç. Dr. Erkan ÜLKER
Yrd. Doç. Dr. Süleyman TOSUN
Yrd. Doç. Dr. Gülay TEZEL

Egzersiz stres testi (EST), koroner arter hastalığının (KAH) tanısında, yaygınlığının değerlendirilmesinde ve prognozunun (hastalığın seyri ve gelişimi hakkında tahmin) tayininde yaygın olarak kullanılan kolay uygulanabilir, ucuz ve invazif (girişimsel) olmayan bir tanı aracıdır. Bu özellikleri nedeniyle klinisyenler tarafından yaygın olarak kullanılmakla birlikte özellikle düşük duyarlılık (%45-92) ve özgüllüğünün (%17-92) yanında lezyon lokalizasyonu hakkında bilgi vermemesi EST'nin kullanımını sınırlayan en önemli kısıtlılıklarıdır. EST'nin

değerlendirilmesinde çok damar hastalığı veya ana koroner arter lezyonları için yüksek risk kriterleri tanımlanmış olmakla birlikte hangi damarda lezyon olduğu söylenememektedir. Bunun tek istisnası EST sırasında ST segment yüksekliği görülmesidir, fakat bu oldukça nadir görülen bir durumdur.

Günümüzde kalp hastalıklarının teşhis edilmesinde invazif ve invazif olmayan tekniklerle elde edilen verilerin yapay zeka yöntemleri ile değerlendirildiği çalışmalar yapılmaktadır. Yapay zeka ve makine öğrenmesi algoritmalarının gelişmesi, karma algoritmaların verimliliğinin artması lineer olmayan sistemlerde karar destek imkanını gerçeğe daha çok yaklaştırmaktadır.

Bu tez çalışmasında her geçen gün tıp alanında daha geniş kullanım imkanı bulan yapay zeka yöntemlerinin EST verilerine dayanarak KAH varlığı ve lezyon lokalizasyonunu belirlemedeki başarısının ve etkinliğinin araştırılması amaçlanmıştır. Çalışma ile sadece KAH'nın tanısı değil lezyon varsa, mevcut lezyonun lokalizasyonunun da belirlenebilmesi amaçlanmıştır. Gerçekleştirilen çeşitli yapay zeka ve makine öğrenmesi modelleri ve ayrıca bu modellerle birlikte uygulanan çeşitli özellik seçim yöntemleri ile EST verilerine dayanarak KAH tahmininde ve lezyon lokalizasyonunu belirlemede konvansiyonel yöntemlerden daha yüksek duyarlılık, özgüllük ve tanısal doğruluk değerleri elde edilmiştir. Aynı zamanda bu çalışma, EST'nin lezyon lokalizasyonunun belirlenmesinde kullanıldığı sınırlı çalışmalardan biridir.

Anahtar Kelimeler : Koroner Arter Hastalığı, Egzersiz Stres Testi, Yapay Zeka Yöntemleri, Makine Öğrenmesi, Sınıflandırma, Özellik Seçimi

ABSTRACT

Ph.D. THESIS

ASSESSMENT OF EXERCISE STRESS TESTING WITH ARTIFICIAL INTELLIGENCE METHODS IN BOTH THE CORONARY ARTERY DISEASE AND THE LESION LOCALIZATION PREDICTIONS

İsmail BABAOĞLU

Selçuk University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Advisor: Assist. Prof. Dr. Erkan ÜLKER

2010, 91 pages

Jury: Prof. Dr. Saadetdin HERDEM
Prof. Dr. Kurtuluş ÖZDEMİR
Yrd. Doç. Dr. Erkan ÜLKER
Yrd. Doç. Dr. Süleyman TOSUN
Yrd. Doç. Dr. Gülay TEZEL

Exercise stress test (EST) is a simple, inexpensive and non-invasive diagnostic tool which is most widely used in the diagnosis and evaluation of prognosis (expected future course and outcome of a disease) of coronary artery disease (CAD). Clinical usefulness has been limited, however, by poor sensitivity (45-92%) and specificity (17-92%) and disability to predict the lesion localization. Although high risk criteria are properly defined for multi-vessel CAD and left main coronary artery lesions in the assessment of EST, it is often difficult to specify which artery has a lesion. Only, there are some data shows that ST segment elevations are indicators of lesion localization, and it is rarely seen.

Today, there are studies, dealing with invasive and non-invasive techniques in the diagnosis of heart diseases as well as artificial intelligence. The development of artificial intelligence and machine learning algorithms and the increase of the efficiency of the hybrid algorithms make decision support process more close to reality in non-linear systems.

In this thesis study, it is aimed to assess the achievement of artificial intelligence techniques, which is becoming more and widely utilizable in medical field day by day, and its efficiency in determining CAD and lesion localization based upon EST data. Not only the diagnosis of CAD, but also the localization of an existing lesion is aimed to be determined in the study. Together with some implemented artificial intelligence and machine learning models and some feature selection methods applied with these models in the study, more sensitivity, specificity and diagnostic accuracy rates are obtained compared to sensitivity specificity and diagnostic accuracy rates obtained from conventional methods on the assessment of CAD and localization of the lesion based upon EST data. Furthermore, this study is one of the rare studies in which EST is used to determine the lesion localization.

Keywords : Coronary Artery Disease, Exercise Stress Test, Artificial Intelligence Techniques, Machine Learning, Classification, Feature Selection

ÖNSÖZ

Bu çalışmanın yürütülmesinde verdikleri destek, gösterdikleri anlayış ve ilgiden dolayı eski danışman hocam Sayın Prof. Dr. Mehmet BAYRAK'a ve yeni danışman hocam Sayın Yrd. Doç Dr. Erkan ÜLKER'e;

Tez izleme komitesinde yer alan ve değerli katkılarıyla çalışmama destek veren Sayın Prof. Dr. Saadetdin HERDEM ve Prof. Dr. Kurtuluş ÖZDEMİR'e;

Çalışmamda desteklerini, eleştirilerini ve yardımlarını esirgemeyen Sayın Yrd. Doç. Dr. Nazif AYGÜL ve Prof. Dr. Bülent Behlül ALTUNKESER'e;

Katkılarından ve yardımlarından dolayı Sayın Yrd. Doç. Dr. Ömer Kaan BAYKAN, Sayın Arş. Gör. Oğuz FINDIK, Sayın Arş. Gör. Dr. Halife KODAZ, Sayın Arş. Gör. Ersin KAYA ve Sayın Yrd. Doç. Dr. Emre ÇOMAK'a;

Çalışmama destek veren Selçuk Üniversitesi Meram Tıp Fakültesi Kardiyoloji Anabilim Dalı ve Selçuk Üniversitesi Selçuklu Tıp Fakültesi Kardiyoloji Anabilim Dalı'na;

Çalışmamda, fikirlerini paylaşmaktan çekinmeyen Selçuk Üniversitesi Bilgisayar Mühendisliği Bölümündeki çalışma arkadaşlarıma;

Özellikle manevi desteğini hiç bir zaman esirgemeyen her zaman ve her konuda hep yanımda olan aileme desteklerinden dolayı teşekkür ederim.

İsmail BABAOĞLU

Konya, 2010

İÇİNDEKİLER

ÖZET ii
ABSTRACT iv
ÖNSÖZ vi
İÇİNDEKİLER vii
SİMGELER VE KISALTMALAR ix
ŞEKİLLER LİSTESİ x
TABLOLAR LİSTESİ xii
1. GİRİŞ 1
1.1. Literatür Araştırması 2
1.2. Tezin Amacı ve Literatüre Katkıları 10
1.3. Tezin Organizasyonu 12
2. PROBLEMİN TANIMI 13
2.1. Koroner Arter Hastalığı (KAH) 13
2.2. Koroner Arter Hastalığı Teşhis Yöntemleri 15
2.2.1. Koroner anjiyografi (KAG) 16
2.2.2. Egzersiz stres testi (EST) 19
2.3. Veri Edinimi 20
3. SINIFLANDIRMA ALGORİTMALARI 24
3.1. Yapay Sinir Ağları (YSA) 24
3.1.1. Çok Katmanlı Yapay Sinir Ağı (ÇKYSA) 26
3.2. Destek Vektör Makinesi (DVM) 28
3.2.1. Lineer destek vektör makinesi 28
3.2.2. Lineer olmayan destek vektör makinesi 30
3.3. Yapay Bağışıklık Tanıma Sistemi (YBTS) 31
3.4. K-En Yakın Komşu (K-NN) 36
3.5. Parçacık Sürü Optimizasyonu ve K-En Yakın Komşu Tabanlı Karma Algoritma (PSO-K-NN) 38
4. ÖN İŞLEME VE ÖZELLİK SEÇİMİ AMACIYLA KULLANILAN ALGORİTMALAR 40

4.1. Genetik Algoritma (GA) ... 40
4.2. Parçacık Sürü Optimizasyonu (PSO) ... 44
4.2.1. İkili parçacık sürü optimizasyonu ... 47
4.3. Ayrıklaştırma ... 48
4.3.1. Eşit-aralığa dayalı ayrıklaştırma ... 50
4.3.2. Eşit-frekansa dayalı ayrıklaştırma ... 51
4.3.3. Entropi tabanlı ayrıklaştırma ... 51
4.4. Temel Bileşen Analizi (TBA) ... 52
5. KAH'NIN TEŞHİSİ KONUSUNDA GERÇEKLEŞTİRİLEN UYGULAMALAR ... 56
5.1. Karşılaştırma ve Doğrulama ... 56
5.1.1. Tanısal testler ... 56
5.1.2. Cohen'in Kappa katsayısı ... 58
5.1.3. Çapraz doğrulama ... 60
5.2. KAH'nın DVM ile Teşhisi ... 61
5.3. KAH'nın DVM ile Teşhisinde GA ve İPSO Kullanarak Özellik Seçimi ... 62
5.4. KAH'nın DVM ile Teşhisinde TBA Kullanılarak Özellik İndirgenmesi ... 68
5.5. KAH'nın DVM ile Teşhisinde Ayrıklaştırma Kullanarak Özellik İndirgenmesi ... 70
5.6. KAH'nın YBTS ile Teşhisi ... 72
5.7. KAH'nın PSO-K-NN ile Teşhisi ... 73
5.8. KAH'nın Teşhisinde YSA ve DVM Yöntemlerinin Karşılaştırılması ... 75
5.9. KAH ve Lezyon Lokalizasyonu Teşhislerinde YSA kullanımı ... 78
6. SONUÇLAR VE ÖNERİLER ... 81
KAYNAKLAR ... 85

SİMGELER VE KISALTMALAR

KAH	: Koroner Arter Hastalığı
KAG	: Koroner Anjiyografi
EST	: Egzersiz Stres Testi
ST	: EKG grafiklerindeki ST bölgesi
YSA	: Yapay Sinir Ağları
EKG	: Elektrokardiyografi
GA	: Genetik Algoritma
PSO	: Parçacık Sürü Optimizasyonu
İPSO	: İkili Parçacık Sürü Optimizasyonu
TBA	: Temel Bileşen Analizi
LMCA	: Sol Ana Koroner Arter (Left Main Coronary Artery)
LAD	: Sol Ön İnen Arter (Left Anterior Descending)
LCx	: Sol Sirkümflex (Left Circumflex)
RCA	: Sağ Ana Koroner Arter (Right Coronary Artery)
PTCA	: Perkütan Translüminal Koroner Anjiyoplasti
DVM	: Destek Vektör Makinesi
YBTS	: Yapay Bağışıklık Tanıma Sistemi
RBF	: Radyal Taban Fonksiyonunu
K-NN	: K-En Yakın Komşuluk

ŞEKİLLER LİSTESİ

Şekil 2.1 Arterde plak oluşumuna bağlı damar lümeninde daralma meydana gelmesi (Berke 2010) 14
Şekil 2.2 Ana koroner arterler ve dallarının şematik gösterimi 15
Şekil 2.3 KAG; KAG sonucu tespit edilen darlık (sol), PTCA işlemi sonrası darlığın durumu (sağ) 18
Şekil 2.4 Koroner Anjiyoplastide balon kullanımı (sol), stent kullanımı (sağ) (Berke 2010) 18
Şekil 3.1 Bir yapay nöronun diyagram olarak gösterimi 24
Şekil 3.2 Yaygın olarak kullanılan transfer fonksiyonları 25
Şekil 3.3 Örnek ÇKYSA modeli 26
Şekil 3.4 (a) Lineer olarak ayrılabilen ve (b) Lineer olarak ayrılamayan DVM yapısı örnekleri (Burges 1998) 30
Şekil 3.5 YBTS algoritmasının adımları 36
Şekil 3.6 Örnek bir veri kümesi için yeni örneğin K-NN metodu ile sınıflandırılması; k=3 komşuluk için sınıflandırma (a), k=1 komşuluk için sınıflandırma (b) 38
Şekil 3.7 PSO-K-NN Algoritması 39
Şekil 4.1 GA'nın yapısal gösterimi 43
Şekil 4.2 PSO'nun yapısal gösterimi 46
Şekil 4.3 Tipik ayrıklaştırma işleminin adımları 50
Şekil 5.1 DVM için RBF çekirdek parametreleri optimizasyon grid'i 62
Şekil 5.2 Sabit γ parametresi için (İPSO-DVM'de $\gamma = 8$; GA-DVM'de $\gamma = 4$; DVM'de $\gamma = 1$) c parametresinin değişimine bağlı eğitim hatasının değişimi 66
Şekil 5.3 Sabit γ parametresi için (İPSO-DVM'de $\gamma = 8$; GA-DVM'de $\gamma = 4$; DVM'de $\gamma = 1$) c parametresinin değişimine bağlı sınıflandırma başarısının değişimi 67

Şekil 5.4 Sabit c parametresi için (İPSO-DVM'de $c = 4$; GA-DVM'de $c = 512$; DVM'de $c = 8$) γ parametresinin değişimine bağlı eğitim hatasının değişimi 67
Şekil 5.5 Sabit c parametresi için (İPSO-DVM'de $c = 4$; GA-DVM'de $c = 512$; DVM'de $c = 8$) γ parametresinin değişimine bağlı sınıflandırma başarısının değişimi 68
Şekil 5.6 Oluşturulan Ağ yapısı 79

TABLOLAR LİSTESİ

Tablo 2.1 Veri Kümesi 23
Tablo 5.1 Hata Matrisi 57
Tablo 5.2 İPSO-DVM, GA-DVM ve DVM yöntemlerine ait en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları 65
Tablo 5.3 TBA ile indirgenmiş veri kümelerinin DVM yöntemi ile sınıflandırılmasında elde edilen en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları 69
Tablo 5.4 TBA-18-DVM ve DVM yöntemlerine ait en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları 70
Tablo 5.5 Ayrıklaştırma ile ön işleme gerçekleştirilmiş DVM modellerine ve ön işleme uygulanmamış DVM modeline ait en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları 71
Tablo 5.6 YBTS parametre optimizasyon aralıkları 72
Tablo 5.7 En uygun YBTS modeline göre sınıflandırma sonuçları 73
Tablo 5.8 En uygun PSO-K-NN, K-NN ve YBTS modellerine göre sınıflandırma sonuçları 74
Tablo 5.9 YSA parametre optimizasyon aralıkları 75
Tablo 5.10 DVM parametre optimizasyon aralıkları 76
Tablo 5.11 Uzman Hekimlerin değerlendirmeleri ile en uygun YSA ve DVM modellerine ait sınıflandırma sonuçları 77
Tablo 5.12 Uzman Hekimlerin değerlendirmeleri ile en uygun YSA ve DVM modellerine ait sınıflandırma sonuçları 78
Tablo 5.13 Ana koroner arterlere ait en uygun YSA modellerine göre sınıflandırma sonuçları 80

1. GİRİŞ

Yapay zeka ve makine öğrenmesi tekniklerinin aritmi, koroner arter hastalığı (KAH), kalp kapak hastalıkları ve akut miyokardiyal enfarktüsler başta olmak üzere birçok kardiyovasküler hastalığın sınıflandırma ve tahmin uygulamalarında kullanılması artan bir fenomen olarak karşımıza çıkmaktadır. Söz konusu hastalıkların riskleri ve tanısal maliyetleri göz önüne alındığında, yapay zeka ve makine öğrenmesi tekniklerinin geliştirilmesi ve pratik kullanımının artırılması konusundaki çalışmalar tıp alanda kaçınılmaz bir hal almaktadır.

KAH gelişmiş ve gelişmekte olan ülkelerdeki mortalite (ölüm oranı) ve morbiditenin (hastalık oranı) en önemli nedenlerinden biridir ve görülme oranı gün geçtikçe artmaktadır. Amerika Birleşik Devletlerinde gerçekleşen ölümlerin yarıdan daha fazlası kardiyovasküler hastalıklara bağlı olarak geçekleşmekte ve bu ölümlerin büyük bir çoğunluğunu da KAH oluşturmaktadır (Gibbons ve ark. 2002). Ülkemize bakıldığında ise 2000 yılında yayınlanan Türk Kalp Raporuna göre Türkiyedeki ölüm nedenlerinin %5'inin kalp damar hastalıklarına ve %35'inin ise KAH'na bağlı olarak gerçekleştiği görülmektedir (Öngen 2001).

Koroner anjiyografi (KAG), şüpheli KAH tanısında günümüzde halen altın standart olarak kabul edilen tanı yöntemidir. Ancak, invazif ve pahalı bir metot olmasının yanında %0.2 – 0.3 mortalite riskine sahip olması nedeniyle KAG, KAH tanısında kullanılabilecek metotlar arasında öncelikli olarak seçilmesi önerilmeyen bir metottur. İnvazif olmaması, daha ucuz, tekrarlanabilir ve güvenli olması sebebiyle egzersiz stres testi (EST), şüpheli KAH tanısında öncelikli olarak kullanılan etkin bir teşhis metodudur. Bununla birlikte, KAH tanısında diğer tanı metotlarına göre düşük duyarlılık ve özgüllüğe sahip olması EST'nin klinik kullanımını kısıtlamaktadır (San Roman ve ark. 1998; Thom ve ark. 2006). EST'nin değerlendirilmesinde, çoklu damar hastalıkları ve sol ana koroner arter lezyonlarını tespit etmek amacıyla bazı yüksek risk kriterleri tanımlanmış olmasına rağmen mevcut bir lezyonun hangi arter üzerinde olduğunu tespit etmek genellikle zordur.

ST segment çökmesinin aksine, EST sırasında ST segment yükselmesinin görülmesi iskemik bölgeyi ve dolaylı olarak lezyonun bulunduğu arteri belirleyebilmekle birlikte, bu durum nadiren görülen bir durumdur (Gallik ve ark. 1993).

Literatürde kardiyovasküler alanda gerçekleştirilen çalışmalar mevcut olmakla birlikte, kardiyologlar tarafından KAH teşhisinde öncelikli olarak kullanılan temel teşhis aracı olan EST verilerinin yapay zeka ya da makine öğrenmesi teknikleri kullanılarak KAH tanısında ve varsa mevcut lezyonun lokalizasyonu konusunda gerçekleştirilen sınırlı sayıda çalışma mevcuttur. Bu bağlamda tez çalışması ile KAH tanısında ve varsa mevcut lezyonun tespitinde EST verilerinin kullanıldığı yapay zeka ve makine öğrenmesi teknikleri ile gerçekleştirilen çeşitli tanı destek modelleri gerçekleştirilmiştir.

Bu tez çalışması konvansiyonel olarak hekimler tarafından değerlendirilen EST verilerinin KAH tanısındaki başarısını yapay zeka ve makine öğrenmesi algoritmaları kullanarak artırmanın yanı sıra, konvansiyonel yöntemler kullanarak düşük duyarlılık ve özgüllük oranları ile elde edilen lezyon lokalizasyonunun başarısını da artırmayı amaçlamıştır. Ayrıca, gerçekleştirilen modellerin başarıları, genetik algoritmalar (GA) ve parçacık sürü optimizasyonunun (PSO) özellik seçim tekniği olarak kullanıldığı modellerin yanı sıra temel bileşen analizi (TBA) ve ayrıklaştırma gibi çeşitli özellik indirgeme teknikleri kullanılarak artırılmaya çalışmıştır. Aynı zamanda, genellikle optimizasyon amacıyla kullanılan PSO ile K-en yakın komşuluk (K-NN) tekniklerinin karma bir biçimde sınıflandırıcı olarak kullanıldığı mevcut sınıflandırıcılara alternatif bir sınıflandırıcı ile EST verilerinin değerlendirildiği bir çalışma da gerçekleştirilmiştir.

1.1. Literatür Araştırması

Yapay zeka ve makine öğrenmesi teknikleri aritmi, KAH, kapak hastalıkları ve akut miyokard enfarktüsü başta olmak üzere birçok kardiyovasküler hastalığın sınıflandırılmasında yaygın olarak kullanılmaktadır.

Kalp kapak hastalıklarının teşhisinde araştırmacılar çeşitli özellik çıkarım metodları ve çeşitli sınıflandırıcılar kullanarak genellikle *Doppler* cihazından alınan verileri işlemeye çalışmışlardır. Kalbin alt ve üst odacıkları arasında yer alan iki kapaktan sağdakine *triküspit* kapak soldakine ise *mitral* kapak adı verilir. Kanın kalbi terk ettiği noktalarda, yani kalp ile ana atardamarlar arasında yer alan diğer iki kapaktan sağdakine *pulmoner* kapak soldakine ise *aort* kapak adı verilir. Kapak hastalıkları belirtilen kapakların herhangi birinin çalışmasını etkileyen hastalıkların genel ismi olarak belirtilebilir. Kalp kapak hastalıkları genel olarak üç grup altında toplanabilir. İlk grup, çeşitli nedenlerle kapakçıkların açılımının kısıtlanması sonucu meydana gelir. İkinci grup, yine çeşitli nedenlerle kapakçıkların kapanmalarındaki bozukluktan meydana gelir. Üçüncü ve en yaygın gözlenen grup ise kapakçıkların hem açılımlarındaki hemde kapanmalarındaki bozukluğun bir arada olması durumunda meydana gelir.

İnvazif olmayan bir tanı aracı olan Doppler, yüksek frekanslı ses dalgalarının dokulara çarpması ve dönen ses dalgalarının işlenerek dokuların görüntülenmesini sağlayan Ultrason adı verilen tanı aracının özel bir türevi olup büyük damarları incelemede kullanılan bir yöntemdir. Doppler yöntemi ile belli bir damarın içindeki kanın akım hızını hem şekil olarak görüntülenebilmekte hem de akım hızına karşı oluşan direnç de matematiksel olarak hesaplanabilmektedir.

Kapak hastalıklarında kolaylıkla kullanılabilen invazif olmayan, ucuz bir tanı aracı olması ve ayrıca geleneksel tıbbi uygulamalarda kapak hastalıklarının teşhisinde çok önemli bir araç olması nedeniyle Doppler, literatürde kapak hastalıkları konusunda çalışan araştırmacıların ilgi odağı olmuştur.

Türkoğlu ve ark. (2002) Doppler cihazından elde ettikleri sinyalleri kullanarak kalp kapak hastalığı varlığını tespit etme yönünde bir çalışma gerçekleştirmişlerdir. Dalgacık ve Fourier dönüşümlerini kullanarak zaman-frekans alanında Doppler cihazından elde edilen sinyallerden özellikler elde etmişlerdir. Elde edilen özellikleri dalgacık dağınımı ve geriye yayılım algoritmasını kullanan bir yapay sinir ağı (YSA) ile sınıflandırarak örneklerin kalp kapak hastalığına sahip olup olmadıklarını belirlemişlerdir.

Türkoğlu ve ark. (2003) bir başka çalışmalarında, Doppler cihazından elde ettikleri sinyallerden dalgacık paket ayrıştırma ve dalgacık paket dağınımından oluşan uyarlanabilir dalgacık dönüşümü kullanarak elde ettikleri özellikleri ileri besleme algoritmasını kullanan bir YSA ile sınıflandırarak, sinyallerin alındığı örneklerin kalp kapak hastalığına sahip olup olmadıklarını belirlemişlerdir.

Çomak ve ark. (2007), Türkoğlu ve ark.'nın (2002) çalışmasının devamı olarak kalp kapak hastalığının teşhisinde kardiyologlara karar destek aracı olarak gerçekleştirdikleri çalışmalarında Doppler cihazından elde sinyaller ile örneklerin kalp kapak hastalığına sahip olup olmadığını araştırmışlardır. Doppler cihazından elde edilen sinyallerden dalgacık dönüşümleri ve Fourier dönüşümleri kullanarak özellikler elde etmişlerdir. Karar destek amacıyla oluşturulan bu sistem dalgacık ve Fourier dönüşümleri sonrasında elde edilen özelliklerin en küçük kareler destek vektör makinesi yardımıyla sınıflandırılmasını sağlamaktadır.

Avci (2009) kalp kapak hastalığının teşhisinde Doppler cihazından elde edilen sinyalleri kullanmıştır. Araştırmacı, dalgacık dönüşümü ile Doppler cihazı sinyallerinden özellikler elde etmiştir. Çalışmada, GA ile destek vektör makinesinin (DVM) birlikteliğinden oluşturulan sistem ile elde edilen özellikler sınıflandırılmış, aynı zamanda en uygun dalgacık filtresi, dalgacık dağınım parametresi ile DVM'nde kullanılan en uygun çekirdek fonksiyon tipi, çekirdek fonksiyon parametreleri ve *C* parametresi belirlenmiştir.

Maglogiannis ve ark. (2009) sistolik ve diyastolik fazlardan elde edilen kalp seslerini kullanarak üzerinde çalışma gerçekleştirdikleri örnekleri "sağlıklı" ya da "hastalıklı" olarak sınıflandırmışlardır. Çalışmada, aort darlığına, mitral darlığa ya da aort üfürümü ya da mitral üfürüme sahip hastalar hastalıklı olarak kabul edilmiştir. Sistolik ve diyastolik fazlardan elde edilen kalp seslerinden dalgacık dönüşümü kullanarak özellikler elde eden araştırmacılar, bu özellikleri DVM ile sınıflandırmışlardır.

Uğuz ve ark. (2008) Doppler cihazından elde edilen sinyalleri kullanarak kalp kapak hastalığı varlığını testpit etmeye çalışmışlardır. Araştırmacılar, Doppler cihazından elde edilen sinyalleri yüksek geçiş filtresinden geçirdikten sonra bu

sinyaller üzerinde gürültü giderim ve normalizasyon işlemlerini gerçekleştirmişlerdir. Belirtilen ön işleme admından sonra dalgacık ve Fourier dönüşümü kullanılarak ön işleme sonrasındaki sinyallerden elde edilen özellikleri ayrık bulanık ve gizli Markov modeli tekniklerini karma olarak kullanarak örneklerin kalp kapak hastalığı varlığının tespitini gerçekleştirmişlerdir.

Yapay zeka ve makine öğrenmesinin kalp hastalıklarında uygulanıldığı bir diğer alan ise aritmi üzerine yapılan çalışmaları kapsamaktadır. Aritmi kalbin ritmik çalışmasındaki bozulma sonucunda meydana gelen hastalıkların genel ismidir. Aritmi KAH, kandaki elektrolit dengesizlikleri, kalp kasındaki fonksiyonel ve anatomik bozukluklar, miyokard enrafktüs sonrası oluşan hasarlar ve by-pass ameliyatı sonrasındaki iyileşme süreci nedenleriyle meydana gelmekle birlikte normal ve sağlıklı kalplerde stres gibi çeşitli nedenlere bağlı olarak da görülebilir. Aritminin teşhisi için kullanılan en yaygın yöntem elektrokardiyografi (EKG)'dir. Ayrıca, bu yöntemin 24 saatlik sürekli EKG çeken genişletilmiş formu olan *Holter* cihazı da aritmi teşhisi için kullanılmaktadır. Gerek EKG cihazından gerekse Holter cihazından elde edilen EKG verileri *atriyal erken atım*, *ventriküler erken atım*, *atriyal fibrilasyon*, *atriyal flutter*, *paroksismal supraventriküler taşikardi*, *ventriküler taşikardi*, *ventriküler fibrilasyon*, *bradiaritmiler* gibi aritmi çeşitlerinin sınıflandırılmasında yaygın olarak kullanılmaktadır.

Literatürde aritmi teşhisi konusunda gerçekleştirilen çalışmaların büyük bir çoğunluğunda araştırmacıların, Kaliforniya Üniversitesi'ne ait açık bir veri tabanı olan UCI veri tabanındaki EKG veri kümesini kullandıkları gözlemlenmiştir.

Polat ve ark. (2006) EKG veri kümesindeki örnekleri aritmiye sahip ya da sağlıklı olarak sınıflandırmak amacıyla bir çalışma gerçekleştirmişlerdir. Araştırmacılar, EKG veri kümesini normalleştirdikten sonra geliştirdikleri bulanık ağırlıklandırma yöntemi ile örneklere ağırlıklar oluşturmuşlar ve gerçekleştirilen bu ön işlemeden sonra da yapay bağışıklık tanıma sistemi (YBTS) yardımı ile bu örnekleri sınıflandırmışlardır.

Bir diğer çalışmlarında Polat ve Güneş (2007) EKG veri kümesi içerisindeki özellik sayısını TBA yöntemini kullanarak indirgemişler ve daha sonra da örnekleri

en küçük kareler destek vektör makinesi kullanarak aritmiye sahip ya da sağlıklı olarak sınıflandırmışlardır.

Özbay ve ark. (2006) aritminin erken teşhisi için geriye yayılım kullanan bir YSA ile geliştirdikleri bulanık kümeleme tabanlı bir sinir ağı sınıflandırıcısını karşılaştırmışlardır. Geliştirilen sistem bulanık c-ortalama kullanarak veri kümesini ağırlıklandıran bir ön işleme sonrası ağırlıklandırılmış verinin sinir ağları yardımı ile sınıflandırılmasını temel almaktadır. Araştırmacılar, kullandıkları veri kümesindeki 10 farklı aritmiyi her iki sınıflandırıcı ile sınıflandırmış ve sonuçları karşılaştırarak geliştirdikleri sınıflandırıcının daha başarılı olduğunu göstermişlerdir.

Ceylan ve Özbay (2007) veri indirgenmesini temel alan çalışmalarında EKG sinyallerine ait veri kümesini sınıflandırarak aritmi teşhisi konusunda veri indirgeme modellerinin performansını karşılaştırmışlardır. Bulanık c-ortalama, TBA, dalgacık dönüşümü ve bulanık c-ortalama ve TBA'nin birlikte kullanıldığı dört farklı veri indirgeme modeli ile ön işlemeye tutulan veri kümesi geriye yayılım algoritması kullanan bir sinir ağı yardımı ile sınıflandırılmış ve her bir veri indirgenme modelinin aritminin sınıflandırılması üzerindeki başarısı karşılaştırılmıştır.

Kannathal ve ark. (2006) aritmi teşhisi için veri kümesinden özellik çıkarımı gerçekleştirerek bu özellikleri adaptif sinirsel-bulanık çıkartım sistemi yardımı ile sınıflandırarak örnekler üzerinde aritmi sınıflandırması yapmışlardır.

Lin ve ark. (2008) aritminin teşhisi için gerçekleştirdikleri çalışmlarında veri kümesini uyarlamalı dalgacık ağını kullanarak sınıflandırmışlardır. Kullanılan metot, Morlet dalgacık dönüşümü ve olasılık tabanlı sinir ağlarının birleşimi olan iki aşamalı bir metottur. Veri kümesinden Morlet dalgacık dönüşümü yardımı ile özellikler elde eden araştırmacılar bu özellikleri olasılık tabanlı sinir ağları ile sınıflandırarak aritmi teşhisini gerçekleştirmişlerdir.

Tanısal destek konusunda yapay zeka ve makine öğrenme algoritmalarının yaygın olarak kullanıldığı araştırma alanında KAH'nın teşhisi konusunda da başarılı çalışmalara rastlamak mümkündür. Literatürde gerçekleştirilen bu çalışmaların genellikle biyokimya verileri ve demografik verilerin kullanılması ile KAH tespitine

yönelik olduğu gözlenmiştir. Bu verilerin yanı sıra EKG verilerinin de kullanılmakta olduğu bazı çalışmalara ilave olarak az sayıda çalışmanın da anjiyografi görüntüleri üzerinden görüntü işleme yöntemleri ile KAH teşhisine yönelik olduğu gözlenmiştir.

Lapuerta ve ark. (1995) biyokimya verilerini kullanarak KAH teşhisine yönelik bir çalışma gerçekleştirlmişlerdir. Kolesterol indirgenmesine bağlı damar tıkanıklığı konusunda gerçekleştirilen araştırmalar nezdinde on yıllık bir periyod boyunca örneklerden alınan serumdaki farklı 7 lipoprotein seviyesinin kullanıldığı çalışmada belirlenen zaman aralığında oluşan KAH, YSA yardımı ile sınıflandırılmıştır.

Mobley ve ark. (2000, 2002, 2005) gerçekleştirdikleri farklı çalışmalarında KAH varlığını ve örneğin erkek ve kadın olmasının KAH üzerindeki etkisini araştırmışlardır. Araştırmacılar veri kümesini örneklerin, yaş, cinsiyet, ırk, sigara içme durumu, diyabet, hipertansiyon, vücut kitle indeksi, kreatinin, trigliserid, kollesterol, yüksek yoğunluklu lipoprotein, kollesterol/ yüksek yoğunluklu lipoprotein oranı, fibrinojen ve lipoprotein düzeyine bağlı olarak demografik ve biyokimyasal verilerinden oluşturmuşlardır. Oluşturulan veri tabanı YSA ve lojistik regresyon kullanılarak sınıflandırılmıştır. Çalışmanın doğruluğunu artırmak amacıyla çapraz-doğrulama yöntemi her iki sınıflandırıcıya da uygulanarak sonuçlar karşılaştırılmalı olarak sunulmuştur. Araştırmacılar Koroner Anjiyografi ve Müdahale Topluluğu'na ait veri tabanını kullanarak cinsiyet ayrımı yaparak ilk çalışmalarına benzer şekilde YSA ile erkeklerdeki ve kadınlardaki KAH teşhisine yönelik iki farklı çalışma daha gerçekleştirmişlerdir. Çalışmalardaki yöntem aynı olmakla birlikte veri kümeleri birbirinden farklıdır. Koroner Anjiyografi ve Müdahale Topluluğu'ndan alınan verilerde EST'nin hekimler tarafından değerlendirilmesi sonucu verilen EST pozitiflik değeri de ek girdi olarak kullanılmıştır.

Scott ve ark. (2004) KAH teşhisine yönelik gerçekleştirdikleri çalışmalarında KAG görüntülerini de kullanan farklı bir yaklaşım sunmuşlardır. EST ve KAG görüntüleri yapay sinir ağları yardımıyla sınıflandırılmıştır. Sınıflandırma sonuçları, genelleştirilmiş klinik teşhis metodu ile karşılaştırıldığında kullanılan metodun daha iyi duyarlılık ve özgüllük değerlerine sahip olduğu gözlemlenmiştir.

Zhidong (2005) KAH teşhisi için diyastol anındaki kalp seslerini DVM kullanarak sınıflandıran bir çalışma gerçekleştirmiştir. Örneklerden, özel olarak tasarlanan yüksek hassasiyete sahip kardiyak bir mikrofonla kalp sesleri alınmış ve ayrıca eş zamanlı olarak EKG'leri de çekilmiştir. Araştırmacı, EKG'leri diyastol'ün başlangıç ve bitiş zamanlarını tespit etmek amacıyla kullanmış ve tespit edilen bu zaman aralığına dayanarak elde edilen diyastol anındaki kalp seslerinin anlık frekanslarını Hilbert-Huang dönüşümü ile ağırlıklandırmıştır. Elde edilen bu özellik vektörleri DVM kullanılarak örnekler hastalıklı ve sağlıklı olarak sınıflandırılmıştır.

Ceylan ve ark. (2007) ateroskleroz'un erken teşhisi amacıyla karotis arterinden alınan Doppler sinyallerini kullanmışlardır. Sol karotis arterinden alınan Dopler sinyallerinin oluşturduğu veri kümesinden TBA yöntemi kullanılarak özellikler çıkartılmış ve bu özellikler karmaşık değerli YSA modeli ile sınıflandırılmıştır. Ayrıca, veri kümesi bulanık c-ortalama yöntemi kullanılarak indirgenmiş ve yine karmaşık değerli yapay sinir ağları modeli ile sınıflandırılmıştır.

Süt ve Şenocak (2007) gerçekleştirikleri çalışmalarında YSA ve tekrarlı sinir ağları ile ikinci derece diskriminant analiz ve lojistik regresyon istatistiksel yöntemlerinin KAH tanısındaki performanslarını karşılaştırmışlardır. Çalışmada demografik ve biyokimyasal veriler içeren veri kümesi, İstanbul Tıp fakültesine başvuran örneklerin yaş, sigara içme durumu, diyabet, hipertansiyon, yaş, vücut kitle indeksi, yüksek yoğunluklu lipoprotein, düşük yoğunluklu lipoprotein, total kollesterol, trigliserit ve kollesterol/yüksek yoğunluklu lipoprotein oranından oluşturulmuştur. YSA'da geriye yayılım algoritması, hızlı yayılım, delta-bar-delta ve genişletilmiş delta-bar-delta algoritmalarını, tekrarlı sinir ağlarında ise Levenberg-Marquardt algoritmasını kullanarak veri kümesi sınıflandırılmış, sonuçlar istatistiksel metotlara ait sınıflandırma sonuçları ile karşılaştırılmıştır.

Kurt ve ark. (2008) yaş, cinsiyet, KAH aile hikayesi, vb. demografik bilgileri kullanarak çeşitli sınıflandırıcıların performanslarını karşılaştırmışlardır. Arştırmacılar, Trakya Üniversitesi tıp fakültesi hastanesinde başvuran örneklere ait oluşturdukları veri kümesini lojistik regresyon, sınıflandırma ve regresyon ağacı, geriye yayılım algoritmasını kullanan yapay sinir ağı, radyal taban fonksiyonunu

(radial basis function – RBF) kullanan sinir ağları ve özdüzenleyici özellik haritaları sınıflandırıcıları ile sınıflandırmış ve sonuçları karşılaştırmalı olarak sunmuşlardır.

Tantimongcolwata ve ark. (2008) iskemik kalp hastalığının erken teşhisinde magnetokardiyogramlardan elde edilen örüntüleri kullanan bir çalışma gerçekleştirmişlerdir. Magnetokardiyogram örüntüleri vücudun farklı bölgelerinden karşılıklı olarak birbirini takip eden dört sıralı ölçüm gerçekleştirilerek elde edilmiştir. Elde edilen örüntüler geriye yayılım algoritmasını kullanan bir YSA ve aktarmasız çekirdekli-özdüzenleyici özellik haritaları kullanarak iskemik kalp hastalığının mevcut olup olmaması konusunda sınıflandırılmıştır.

McMahon ve ark. (2008) Dopler cihazından elde ettikleri strain dalga formu değerlerini kullanarak akut miyokardiyal iskemi teşhisine yönelik bir çalışma gerçekleştirmişlerdir. Araştırmacılar, örneklerden aldıkları Dopler sinyalerini Dopler cihazı üzerinde bulunan bir yazılım ile iki boyutlu strain dalga formu haline dönüştürmüşlerdir. Her bir strain dalga formundan 70 eşit uzaklıklı özellik elde edilmiş ve bu özellikler yapay sinir ağları yardımıyla akut miyokardiyal iskeminin teşhisi gerçekleştirilmiştir.

Antanavicius ve ark. (2008) EKG sinyallerinin doğrusal olmayan dinamiklerin analizi ile KAH'nın teşhisine yönelik bir çalışma gerçekleştirmişlerdir. Lineer olmayan dinamik tanımlayıcılar istirahat durumundaki EKG sinyallerinin 12 derivasyonundan oluşturulmuştur. Kaunas Tıp Fakültesi Kardiyoloji Enstitüsünden edinilen 162 erkek ve 42 bayan hastaya ait EKG kayıtları lineer olmayan dinamik tanımlayıcılar kullanılarak değerlendirilmiş ve segment lokalizasyonuna çalışılmıştır. Bölüm 2.1'de detayları verilen koroner arterlerden RCA 4 alt segmente, LAD ve LCx ise 5'er alt segmene ayrılarak segment lokalizasyonu gerçekleştirilmiştir.

Cios ve ark. (1994) KAH teşhisi ve lezyon lokalizasyonu için karma bir algoritma önermişlerdir. Doksan bir hastaya ait sintigrafi görüntülerini üç farklı kural çıkarım yöntemi ile değerlendirdikten sonra elde edilen kuralları bulanık kurallara çevirerek sınıflandırma işlemini gerçekleştirmişlerdir.

Çolak ve ark. (2008) KAH teşhisi için değişik sekiz öğrenme algoritmasına bağlı farklı YSA modellerinin başarısını değerlendirmişlerdir. Ana epikardiyal arterlerinden herhangi birinde %50'den daha büyük darlığa sahip olan 237 adet hastayı çalışmaya dahil edilmiştir. Bu ölçütte bir darlık anlamlı olarak kabul edilmiş ve KAH varlığı şeklinde yorumlanarak çalışmanın çıkış değerini oluşturmuştur. Hastalardan elde edilen yaş, cinsiyet, kan basıncı, hastanın diyabetinin olup olmaması gibi demografik bilgiler ile düşük yoğunluklu lipoprotein (LDL), üre, trigliserit gibi biyokimyasal veriler giriş vektörünü oluşturmuştur. Araştırmacılar çok katmanlı YSA ile giriş ve çıkış verilerine bağlı olarak KAH teşhisine çalışmışlardır. Araştırmacılar, çok katmanlı yapay sinir ağını eğitirken sekiz farklı öğrenme algoritması kullanmış ve oluşturdukları modellerin başarılarını karşılaştırmışlardır.

1.2. Tezin Amacı ve Literatüre Katkıları

Literatürde KAH tanısında gerçekleştirilen çalışmaların büyük bir çoğunluğunun örneklerin demografik ve biyokimya bilgilerine dayanarak KAH teşhisine yönelik gerçekleştirildiği gözlemlenmiştir. KAH tanısındaki altın standart olarak kullanılan teşhis yöntemi KAG'dir. Ancak invazif olması, maliyetli olması ve mortalite ve morbidite riski içermesi nedeniyle sıklıkla en son tercih olarak kullanılan bir yöntemdir. Diğer yöntemlerle karşılaştırıldığında EST, invazif olmaması, nispeten daha ucuz olması, tekrarlanabilir ve daha güvenli bir yöntem olması sebebiyle kardiyologların KAH tanısında öncelikli olarak kullandıkları bir teşhis yöntemidir. Bu nedenle bu tez çalışmasında KAH teşhisinde ve KAH varsa mevcut lezyonun lokalizasyonunda EST verileri kullanılarak çeşitli yapay zeka ve makine öğrenmesi algoritmalarının etkinliği araştırılmıştır.

Konvansiyonel yöntemler ile kardiyologların KAH tanısındaki EST değerlendirmeleri bazı istisna durumlar haricinde düşük duyarlılık ve özgüllük değerlerine sahiptir. Bu tez çalışması ile yapay zeka ve makine öğrenmesi yöntemleri kullanılarak EST verilerine dayanan KAH tanısında çeşitli modeller oluşturularak testin duyarlılık ve özgüllük değerlerinin artırılması amaçlanmıştır. Bu bağlamda

çalışma, KAH tanısında EST verilerini standart dört farklı yapay zeka ve makine öğrenmesi metotlarına ve yeni geliştirilen karma bir metoda göre değerlendirmeyi, bu değerlendirme esnasında da dört farklı özellik seçim yöntemi ile başarıyı artırmayı amaçlamaktadır.

Literatürde KAH tanısı konusunda çeşitli çalışmalar mevcut olmakla birlikte mevcut lezyonun lokalizasyonu konusunda çok sınırlı sayıda çalışmaya rastlanmıştır. *Lezyon lokalizasyonu* ifadesi KAH varlığında mevcut lezyonun kalbi besleyen dört büyük koroner arterden hangisi ya da hangilerinde olduğunun tam olarak tespiti olarak tanımlanabilir. Bu tez çalışması ile EST verilerine dayanarak KAH varlığının tespitinin yanında varsa mevcut lezyonun lokalizasyonunun da gerçekleştirilmesi amaçlanmıştır.

Öngörümüze göre, EST verilerine dayanarak gerek KAH tanısı gerekse mevcut lezyonun lokalizasyonu konusunda gerçekleştirilecek çalışmalar sonucunda oluşacak olan hastalık teşhis sistemleri kardiyologlara KAG öncesi bir klinik destek sistemi olarak sunulabilecektir.

Bu tez çalışmasının literatüre katkıları maddeler halinde özetlenmek istenirse; bu tez çalışması ile

1. Yapay zeka ve makine öğrenmesi yöntemleri kullanılarak EST verilerine dayanan KAH tanısında çeşitli modeller oluşturularak testin duyarlılık ve özgüllük değerlerinin artırılması,
2. EST verilerine dayanarak KAH varlığının tespitinin yanında varsa mevcut lezyonun lokalizasyonunun da gerçekleştirilmesi,
3. Çalışmalar sonucunda oluşacak olan hastalık teşhis sistemleri kardiyologlara KAG öncesi bir klinik destek sistemi olarak sunulabilmesi amaçlanmıştır.

1.3. Tezin Organizasyonu

EST verilerine dayanarak KAH'nın ve mevcut lezyonun lokalizasyonunun teşhisi konusunda gerçekleştirilen bu tez çalışması aşağıdaki gibi organize edilmiştir;

Birinci bölümde, tez çalışmasının konusu ve kapsamı hakkında genel bir özet verilmektedir. Çalışmanın amacı, literatürdeki mevcut çalışmalar ve çalışmanın literatüre katkıları verilmiştir.

İkinci bölümde KAH, KAH'nın teşhis yöntemleri, KAG ve EST'nin nasıl gerçekleştirildiği, tez çalışmasında kullanılan veri kümesinin nasıl elde edildiği ve bu veriye ait özellikler verilmektedir.

Üçüncü bölümde, EST verileri kullanarak KAH'nın varlığı ve mevcut lokalizasyonu konusunda gerçekleştirilmiş modellere ait sınıflandırma yöntemleri verilmektedir.

Dördüncü bölümde, EST veri kümesinin değerlendirilmesinde sınıflandırıcılarla birlikte kullanılan özellik seçim algoritmaları verilmektedir.

Beşinci bölümde, EST verileri kullanarak KAH'nın varlığı ve mevcut lokalizasyonu konusunda gerek özellik seçimi kullanılarak gerekse kullanılmadan gerçekleştirilmiş sınıflandırma modelleri ve bu modellerden elde edilen sonuçlar verilmektedir.

Altıncı bölümde, gerçekleştirilen çalışmaların sonuçları değerlendirilmiş ve gelecekte başarının artırılması konusunda uygulanabilir olası yöntemler verilmiştir.

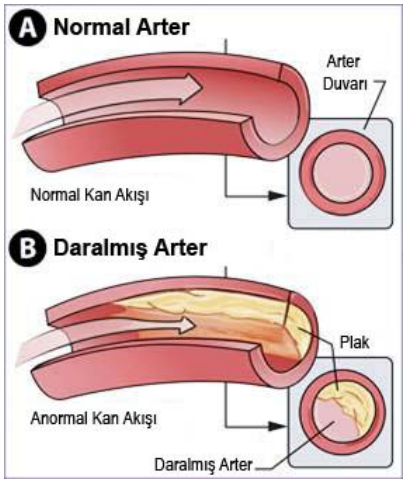
Yedinci bölümde ise tez çalışmasında kullanılan kaynaklara yer verilmiştir.

2. PROBLEMİN TANIMI

2.1. Koroner Arter Hastalığı (KAH)

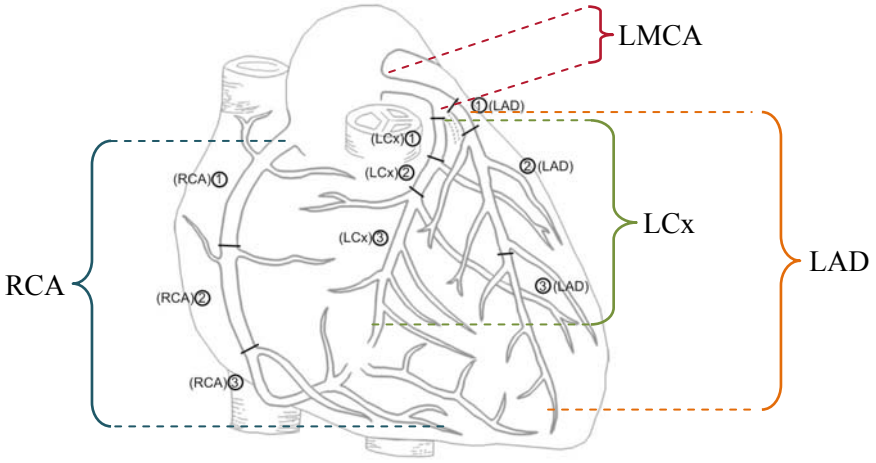
Aterosklerotik damar hastalığı büyük ve orta boyuttaki arterlerin temel olarak *intima* (damarın en iç tabakası, gömleği) tabakasına yerleşen, zamanla kan akımını etkileyecek şekilde damar lümeninde daralmaya neden olan kesintisiz (kronik) bir süreçtir. Bütün arter yatağı damar tıkanıklığından eşit düzeyde etkilenmez. Kan akımını engelleyecek boyutlara ulaştığında klinik bulgular vermeye başlayan bu süreçte koroner arterlerin, karotislerin, özellikle karın aortunun, böbrek arterlerinin ve alt ekstremite arterlerinin daha çok tutulduğu gözlemlenmektedir (Öngen 2001).

Vücudumuzdaki damarların normal elastik yapısını kaybederek sertleşmesi ve *plak* olarak adlandırılan kolesterolden zengin materyalin birikmesi sonucu damar lümeninde daralma veya tıkanıklık oluşmaktadır (bkz. Şekil 2.1). Tıkanıklığı oluşturan plak yağ, kolesterol, kalsiyum ya da kanda bulunan maddelerden meydana gelmektedir. Arterlerin iç yüzeyinde biriken plak kanın akışını engeller ve dolayısıyla hücreler yeterli oksijeni ve besini alamaz. Bu durum hemen hemen bütün arterlerde meydana gelmekle birlikte en yaygın ve önemli olarak koroner arterlerde meydana gelmekte ve neticede KAH ortaya çıkmaktadır.



Şekil 2.1 Arterde plak oluşumuna bağlı damar lümeninde daralma meydana gelmesi (Berke 2010)

Koroner arterler kalp dokusuna oksijen taşıyarak onu besleyen atardamarlardır. Kalbin epikardiyal bölgesinde yer alırlar. Aort kökünden sol taraftan çıkan sol ana koroner arter (LMCA – Left main coronary artery) yaklaşık 3-6 cm uzunluğundadır. LMCA (Left main coronary artery), sol ön inen arter (LAD – Left anterior descending) ve sol sirkümfleks (LCx – Left circumflex) olarak iki ana damara ayrılmaktadırlar. Bir diğer büyük koroner arter olan sağ koroner arter (RCA – Right coronary artery) ise aort kökünden sağ taraftan çıkar. Kalbin epikardiyal dokusu üzerinde yer alan koroner arterler bu arterlerden çıkan daha küçük dallara ayrılarak kalp hücrelerine ulaşırlar. Koroner arterlerin kalp üzerindeki konumlarının bir gösterimi Şekil 2.2'de verilmektedir.



Şekil 2.2 Ana koroner arterler ve dallarının şematik gösterimi

Hasta istirahat halinde iken (bazal hal) kalp, KAH varlığına ait herhangi bir belirti veya bulgu vermeyebilir. Fakat kalp, egzersiz sırasında daha fazla kana ihtiyaç duyacaktır. Daralma veya tıkanıklığı olan koronerler egzersiz sırasında artan ihtiyacı karşılamakta yetersiz kalacaklardır. Bu nedenle KAH varlığının belirtileri bazen sadece egzersiz sırasında ortaya çıkmaktadır. Yeterince kan alamayan kalp kası hücreleri iskemi nedeniyle göğüs ağrısı ve EKG'de özellikle ST segmentinde bazı değişiklikler oluşmasına neden olacaktır. Bu durum EST'nin elektrofizyolojik temelini oluşturmaktadır.

2.2. Koroner Arter Hastalığı Teşhis Yöntemleri

KAH tanısında hastanın hikayesinin yanında, EKG, EST, radyolojik tetkikler (Sintigrafi vb) ve KAG gibi tetkikler kullanılmaktadır. EKG, kalp kasının ve kasa ait sinirsel iletimin çalışmasını incelemek üzere kalpte meydana gelen elektriksel faaliyetlerin kaydedilmesi olarak tanımlanır. KAH'na ait bazı bulguların sadece eforla ortaya çıkması nedeniyle EKG stabil KAH tanısında düşük özgüllük ve duyarlılık değerlerine sahiptir ve normal olması KAH'nı ekarte ettirmemektedir. Sintigrafi ise vücuttaki organların dokuların veya vücuttaki herhangi bir oluşumun

kişiye verilen radyoaktif elementlerle işaretli kimyasal ilaçların incelenen organda ve dokuda tutuluşu, dağılımı, atılışı gibi organın fonksiyonel olarak görüntülenmesi olarak tanımlanır. Sintigrafi de göreceli olarak maliyetli olması nedeniyle, KAH tanısı için ilk tercih olarak kullanılmayan bir teşhis yöntemidir.

EST, tıbbi gözetim altında bireylerin kalp hızlarını ve kalbin yaptığı işi egzersiz yoluyla artırarak sürekli EKG kayıtlarının alınması ile gerçekleştirilen bir yöntemdir. Bu yöntem, mevcut damar daralma veya tıkanıklıkların kalp üzerindeki olumsuz etkisini egzersiz aracılığıyla artırarak EKG'de istirahat sırasında görülmeyen bazı değişikliklerin ortaya çıkartılması esasına dayanan KAH'nın etkin teşhisine yardımcı olmak üzere gerçekleştirilmektedir. Günümüzde, yüksek özgüllük ve duyarlılık içeren diğer yöntemlere göre maliyeti daha ucuz olan bu yöntem hekimlerin KAH tanısında ilk tercih ettikleri yöntemlerden birisi olarak kullanılmaktadır.

İnvazif/girişimsel bir yöntem olan KAG, KAH tanısında en etkili yöntem olarak kullanılmaktadır. Arterlere verilen radyo-opak madde ile invazif olarak sürekli radyoaktif görüntüleme ile gerçekleştirilen bu yöntem KAH tanısında en etkili yöntem olmasına karşın diğer tanısal testlere göre daha çok mortalite ve morbidite riskine sahip olduğu için bireylere KAG gerçekleştirilmesinden önce daha düşük riske sahip başka bir yöntemin KAH varlığı konusundaki sonuçları beklenir. Bir başka değişle, genellikle düşük mortalite ve morbidite risklerine sahip bir testin bireyde KAH varlığı konusunda pozitif bir yargısı oluşmuş ise bireye KAG testi yapılmasına karar verilir.

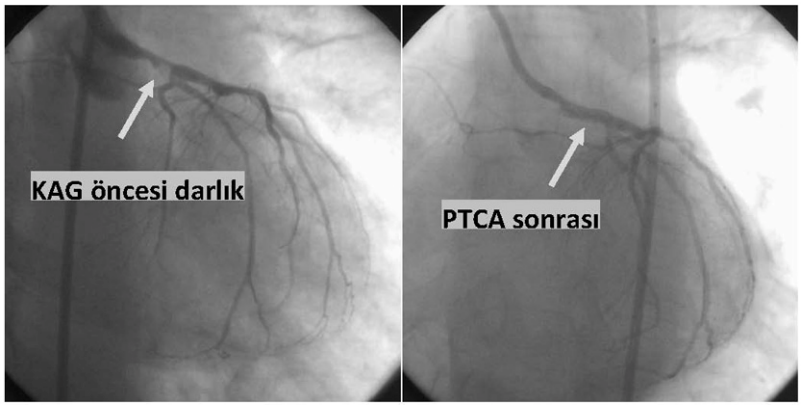
2.2.1. Koroner anjiyografi (KAG)

KAH'nda aterosklerotik lezyonun yerini ve tıkanıklık oranını belirlemede ve kesin tanıda en etkili yöntem KAG'dir. KAG, damarlar içerisinde dolaşabilecek incelikte ve esneklikte, koroner arterlere ulaşabilecek uzunluktaki tüpler yardımıyla çeşitli özelliklere sahip boyalı maddelerin koroner arterlere verilerek koroner arterlerin görüntülenmesi işlemi olarak tanımlanabilir. Burada öncelikle KAG

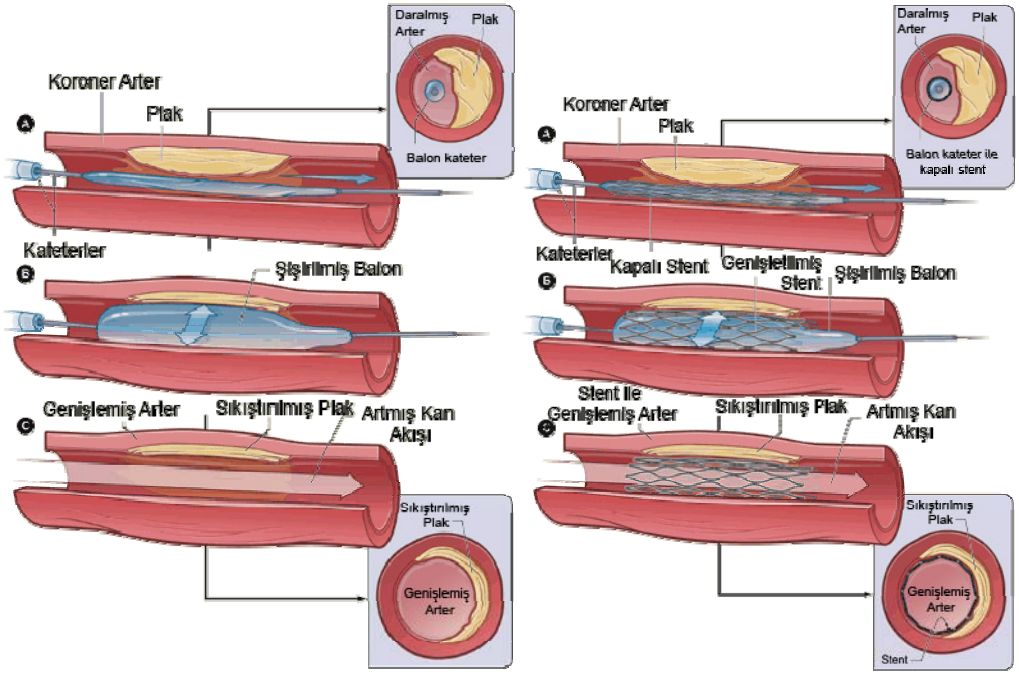
yapılacak hastaya sakinleştirici bir ilaç verilir. Daha sonra, hastanın atardamarına *kateter* veya *sheath* adı verilen ince tüpler vasıtasıyla yerleşilir. KAG, genellikle hastanın sağ kasık bölgesinde bulunan atardamar (femoralis) üzerinden gerçekleştirilir. Görüntülenmek istenen damarın özelliğine göre, uygun kullanıldığında damar zedelenmesine yol açmayan, pıhtı oluşturmayan özel maddelerden yapılmış kateterler kullanılır. Kardiyologlar, bu kateterler yardımıyla ulaşmak istedikleri damara ulaşırlar. İncelenen arter, *radyo-opak* madde adı verilen, röntgen ışığı altında fark edilen boyalı maddeyle görüntülenir. Görüntülenme sonrası tıkanıklık olup olmadığı, yeri ve tıkanıklık yüzdesi kaydedilir.

KAH'nın tedavisinde, KAG ile kalp damarlarının görüntülenmesinden sonra, aynı işlem sırasında veya ikinci bir seansta daralmış veya tıkanık damarları *balon* (PTCA-Perkütan translüminal koroner anjiyoplasti) veya *stent* (tel kafes) yöntemi ile açmak mümkün olmaktadır. Balon yönteminde darlık bölgesine kadar çok ince bir kılavuz tel yardımıyla ince bir balon sönük halde ilerletilir, tam darlığın üzerinde bu balon şişirilerek o bölge genişletilir. Darlık balon yöntemi ile giderilemeyecek niteliklerde ise bu darlık bölgesine stent takılabilir. Stent, balon yöntemine benzer şekilde darlık bölgesine getirildikten sonra şişirilir ve damar genişletilir. Stent damarda bırakılır. Eğer koroner arterler bu yöntemlerle ameliyatsız olarak açılamayacaksa, koroner arter by-pass ameliyatı tavsiye edilir.

KAG, KAH tanısında kullanılan oldukça pahalı bir yöntemdir. İnvazif bir teknik olması sebebiyle KAG, %1-2 komplikasyon oranına, %0.1-0.2 mortalite ve miyokard enfarktüsü oranına sahiptir. Şekil 2.3'de KAH'na sahip bir bireyin KAG görüntüsü, tedavi (PTCA) sonrası görüntüsü ve Şekil 2.4'de PTCA işleminde balon ve stentin nasıl kullanıldığına ait bir çizim gözlemlenmektedir.



Şekil 2.3 KAG; KAG sonucu tespit edilen darlık (sol), PTCA işlemi sonrası darlığın durumu (sağ)



Şekil 2.4 Koroner Anjiyoplastide balon kullanımı (sol), stent kullanımı (sağ) (Berke 2010)

2.2.2. Egzersiz stres testi (EST)

Egzersiz istirahat halinde mevcut olmayan kardiyovasküler şikayet ve bulguların ve kardiyak fonksiyonlarının yeterliliğinin değerlendirilmesi amacıyla yaygın olarak kullanılan fiziksel bir zorlamadır. Eforlu EKG, egzersiz EKG, egzersiz stres testi, efor stres testi ve Trademil testi olarak da adlandırılan EST, şüpheli ya da ispatlanmış kardiyovasküler hastalığa sahip bireyleri değerlendirmek amacıyla en yaygın kullanılan ve invazif olmayan bir yöntemdir. EST temel olarak prognozun (hastalığın gelişim sürecinin) tahmininde ve KAH'nın olasılığının ve derecesinin belirlenmesinde ve ayrıca gerçekleştirilen tedavinin etkilerinin gözlemlenmesinde kullanılır (Chaitman 2005).

EST'nin uygulanması tanımından da anlaşılacağı üzere basit anlamda çeşitli derecelerde efora maruz bırakılmış bireylerin sürekli EKG'lerinin çekilmesini amaçlamaktadır. Buna göre, bireyin öncelikle istirahat halindeki (bazal hal) kalp hızı, kan basıncı ve EKG'si kaydedilir. Genellikle bireye 10 elektrota sahip 12-lead EKG ölçüm cihazı bağlanır. Birey EST cihazının çeşidine göre koşu bandı üzerinde koşarak, sabit bisikletin pedallarını çevirerek ya da eforu simule eden ilaçlar yardımı ile efora maruz bırakılmaktadır. Test, bazal halde bireye ait kalp hızı, kan basıncı ve EKG değerlerinin alınmasından sonra hastaya genellikle 3'er dakikalık evrelerle artan eforun yaklaşık 12-15 dakika kadar uygulanması ve bu uygulama sürecinde de bireyin sürekli EKG'sinin alınması şeklinde gerçekleşmektedir. Normal bir birey için EST'nin gerçekleştirileceği 3'er dakikalık toplam evre sayısı 5 olacaktır. EST bireyin testi kendi isteği ya da hekimlerin yeterli görmesi sonucu egzersizi sonlandırmasına kadar geçen kısmı egzersiz, testin sonlandırılmasından sonra hastanın kan basıncının ve kalp hızının normal değerlere dönmesi için geçen kısmı da düzelme olarak adlandırılır. Egzersiz sırasındaki kalp aktivitelerinin yanında düzelme aşamasındaki aktivitelerin de değerlendirmeye tabi tutulması ile daha detaylı değerlendirme yapmak mümkündür.

2.3. Veri Edinimi

Tez çalışmasında kullanılan veriler Selçuk Üniversitesi Meram Tıp Fakültesi Hastanesi Kardiyoloji Anabilim Dalı EST ve Koroner Anjiyografi ve Kateterizasyon laboratuarlarından elde edilmiştir.

Çeşitli şikayetlerle polikliniğe başvuran hastalardan KAH şüphesi ile EST yapılan ve ardından da KAG gerçekleştirilen 480 adet birey çalışmada kullanılmıştır. Bireylere ait EST sonuçlarının yanında, temel demografik bilgileri (yaş, cinsiyet, aile hikayesi, vb.), EST anındaki istirahat ve peak (zirve – EST'nin sonlandırıldığı aşama) kalp hızı, kan basıncı ve EST için geçen toplam süre de kaydedilmiştir.

EST sonuçları 2 uzman kardiyolog tarafından değerlendirilmiştir. Tez çalışmasında, bu değerlendirmede uzman kardiyologların EST sonuçlarına bakarak gerçekleştirdikleri KAH tahmini konusundaki uzmanlıklarına dayanan sınıflandırma sonuçları *EST uzman hekim değerlendirme* (UHD) sonuçları olarak ifade edilmektedir. EST'nin peak aşamasında J noktasından 60ms sonra gerçekleşen ST segment çökme ve yükselmeleri her bir derivasyon için kaydedilmiştir. UHD işleminde hekimler KAH varlığını gösteren pozitif bir EST'yi geleneksel yöntemlere göre ardışık iki klavuz'da(lead) 1mm'den büyük yatay ya da inişte olan ST segment çökmesi ya da yükselmesine rastlanması olarak tanımlamışlardır.

Çalışmada kullanılan 480 bireyin tamamına EST uygulanmasını takip eden 1 ay içerisinde KAG işlemi gerçekleştirilmiştir. KAG görüntüleri yine 2 uzman kardiyolog tarafından değerlendirilmiştir. LMCA'da %50'den büyük olan, diğer 3 ana epikardiyal koroner arterde ise %70'den büyük olan darlık önemli KAH varlığı olarak kabul edilmiştir. KAH varlığı durumunda lezyonun LMCA dışındaki diğer 3 ana epikardiyal koroner arter üzerindeki konumları da kaydedilmiştir. RCA, LAD ve LCx uzman kardiyologların deneyimlerine dayanarak her biri 3 alt parçaya ayrılmıştır. Belirlenen alt parçalar Şekil 2.2'de verilmiştir. LMCA, LAD ve LCx alt dallarına ayrılmaktadır. Dolayısıyla çalışmada LMCA olarak adlandırılan ana koroner arter, LAD ve LCx alt dallarına ayrılmadan önceki kısım olarak

belirtilmiştir. Bu nedenle LMCA üzerinde oluşacak bir lezyon için lezyonun bulunacağı konum belirlenmemiştir.

EST'nin hekimler tarafından değerlendirmesini zorlaştıran veya tamamen imkansız hale getiren dal bloklarına (sağ dal bloğu, sol dal bloğu), pre-excitation sendromuna, atriyal fibrilasyona, sol ventriküler hipertropiye sahip ve Digoxin kullanan bireyler çalışmanın dışında tutulmuştur.

Tez çalışmasında kullanılan bireylere ait elde edilen giriş ve çıkış özelliklerinin tanıtımı aşağıdaki gibi gerçekleştirilerek veri kümesinin dağılımı Tablo 2.1'te verilmiştir.

Çıkış vektörü olarak kullanılan ve KAG'den elde edilen özellikler:

1. *KAH*: KAH'nın varlığını belirtmektedir. Birey KAH'na sahipse 1 değilse 0 değerini almaktadır.
2. *LMCA*: LMCA üzerinde mevcut lezyonun konumunu belirtmektedir. Birey LMCA üzerinde bir lezyona sahip değilse 0, sahipse 1 değerini almaktadır.
3. *LAD*: LAD üzerinde mevcut lezyonun konumunu belirtmektedir. Birey LAD üzerinde bir lezyona sahip değilse 0, sahipse belirlenen 3 konumdan birinin değerini, yani 1,2 ve 3 değerlerini almaktadır.
4. *RCA*: RCA üzerinde mevcut lezyonun konumunu belirtmektedir. Birey RCA üzerinde bir lezyona sahip değilse 0, sahipse belirlenen 3 konumdan birinin değerini, yani 1,2 ve 3 değerlerini almaktadır.
5. *LCx*: LCx üzerinde mevcut lezyonun konumunu belirtmektedir. Birey LCx üzerinde bir lezyona sahip değilse 0, sahipse belirlenen 3 konumdan birinin değerini, yani 1,2 ve 3 değerlerini almaktadır.

Giriş vektörü olarak kullanılan ve EST ile bireye ait demografik bilgilerden elde edilen özellikler:

1. *İST* : İstirahat halindeki bireyin ST değişikliğine sahip olma durumunu belirtmektedir. Birey istirahat halinde ST değişikliğine sahipse 1, değilse 0 değerini almaktadır.
2. *Yaş* : Bireyin yaşını belirtmektedir.

3. *Cinsiyet* : Bireyin cinsiyetini belirtmektedir. Kadın hastalar 0, erkek hastalar ise 1 değerini almaktadır.
4. *KH* : Bireyin istirahat halindeki kalp hızını belirtmektedir.
5. *PEvre* : Bireyin peak evresini belirtmektedir.
6. *Süre* : EST'nin gerçekleştirildiği toplam süreyi saniye cinsinden belirtmektedir.
7. *PKH* : Bireyin peak kalp hızını belirtmektedir.
8. *MET's* : Bireyin MET's (metabolik eşdeğer – metabolic equivalent) değerini belirtmektedir.
9. *SNeden* : EST'nin sonlandırma nedenini belirtmektedir. Eğer birey hedeflenen kalp hızına erişmişse 1 değerini, ST segment değişikliği oluşmuşsa 2 değerini, diğer nedenler için 3 değerini almaktadır.
10. *GAğrısı* : EST sırasında bireyin göğüs ağrısına sahip olup olmadığın belirmektedir. Bireyde göğüs ağrısı oluşmuşsa 1 değerini, oluşmamışsa 0 değerini almaktadır.
11. *GeçmişKriz*: Bireyin daha önceden kalp krizi geçirip geçirmediğini belirtmektedir. Birey daha önceden kalp krizi geçirdiyse 1 değerini, aksi halde 0 değerini almaktadır.
12. *D1* : Peak evresindeki D1 derivasyonu.
13. *D2* : Peak evresindeki D2 derivasyonu.
14. *D3* : Peak evresindeki D3 derivasyonu.
15. *aVR* : Peak evresindeki aVR derivasyonu.
16. *aVL* : Peak evresindeki aVL derivasyonu.
17. *aVF* : Peak evresindeki aVF derivasyonu.
18. *V1* : Peak evresindeki V1 derivasyonu.
19. *V2* : Peak evresindeki V2 derivasyonu.
20. *V3* : Peak evresindeki V3 derivasyonu.
21. *V4* : Peak evresindeki V4 derivasyonu.
22. *V5* : Peak evresindeki V5 derivasyonu.
23. *V6* : Peak evresindeki V6 derivasyonu.

Tablo 2.1 Veri Kümesi

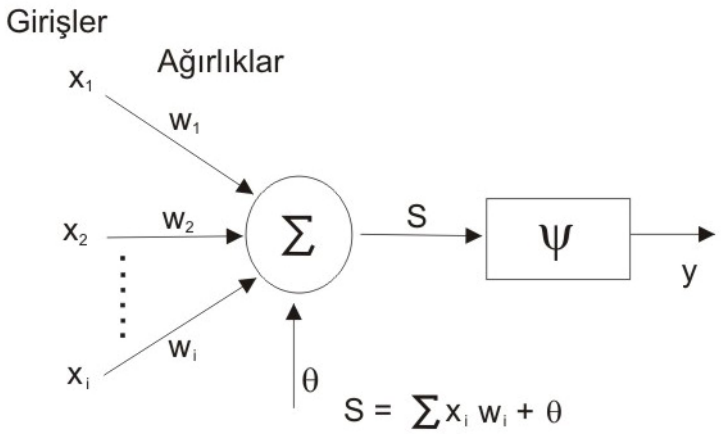
Çıkış değeri olarak kullanılan özellikler						
Özellik	**Birim**	**Aralık**		**Ort**	**SSapma**	**Ortn**
		Min	**Mak**			
1. KAH	Yok (0), Var(1)	0	1	0,72	0,44	NA
2. LMCA	Yok (0), Var(1)					
3. LAD	Yok (0), Konumuna göre: Var(1), Var(2), Var(3)					
4. RCA	Yok (0), Konumuna göre: Var(1), Var(2), Var(3)					
5. LCx	Yok (0), Konumuna göre: Var(1), Var(2), Var(3)					
Giriş değeri olarak kullanılan özellikler						
Özellik	**Tanım ve Birim**	**Aralık**		**Ort**	**SSapma**	**Ortn**
		Min	**Mak**			
1. İST	Yok (0), Var (1)	0	1	0,18	0,38	-
2. Yaş	Yıl	18	83	57,74	10,28	58
3. Cinsiyet	Kadın (0), Erkek(1)	0	1	0,71	0,45	-
4. KH	Dakikadaki atım sayısı	50	135	82,91	14,98	82
5. P Evre	Evre 1, Evre 2, Evre 3, Evre 4, Evre 5	1	5	3,07	0,86	-
6. Süre	Saniye	56	831	452,91	147,99	450
7. PKH	Dakikadaki atım sayısı	82	186	141,11	19,49	141,5
8. METs	METs	2	16,9	9,30	2,68	9,7
9.SNeden	Hedef Kalp Hızı (1), ST Değişikliği (2), Diğer (3)	1	3	2,27	0,80	2
10. GAğrısı	Yok(0), Var(1)	0	1	0,27	0,44	-
11. GeçmişKriz	Yok(0), Var (1)	0	1	0,12	0,32	-
12. D1	Milimetre	-3,25	0,25	-0,33	0,47	0
13. D2	Milimetre	-4,25	0,25	-1,11	1,00	-1
14. D3	Milimetre	-4	3	-0,83	0,89	-0,75
15. aVR	Milimetre	0	3	0,58	0,71	0,25
16. aVL	Milimetre	-3	2	0,13	0,52	0
17. aVF	Milimetre	-4	1	-0,95	0,89	-1
18. V1	Milimetre	-1,25	2	0,45	0,51	0,5
19. V2	Milimetre	-2,5	2	-0,09	0,45	0
20. V3	Milimetre	-4	2	-0,26	0,61	0
21. V4	Milimetre	-6,75	3	-0,74	0,99	-0,5
22. V5	Milimetre	-4,75	1,5	-1,24	1,03	-1,25
23. V6	Milimetre	-5,25	2,75	-1,22	0,96	-1,25

3. SINIFLANDIRMA ALGORİTMALARI

3.1. Yapay Sinir Ağları (YSA)

YSA, biyolojik sinir ağlarının modellenmesi ile geliştirilmiş bir yapay zeka tekniğidir. Günümüzde lineer olmayan problemlerin çözümünde ağırlıklı olarak kullanılan bu algoritma, aldığı giriş verilerini biyolojik sinir hücrelerini modelleyen yapay sinir hücrelerinin (nöron) çeşitli şekillerde birbirlerine bağlanmasıyla oluşturduğu YSA'nda değerlendirerek çıkış parametreleri olarak sunmak amacına yönelik bir şekilde çalışır (Sağıroğlu ve ark. 2003; Baykan 2007; Serhatlioglu ve ark. 2003).

Çeşitli şekillerde birbirlerine bağlanarak YSA'yı oluşturan bir yapay nöron temel olarak girişler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış olmak üzere beş bölümde incelenebilir (Rumelhart ve ark. 1994; Baykan 2007). Bir yapay nöronun diyagram olarak gösterimi Şekil 3.1'de verilmiştir.



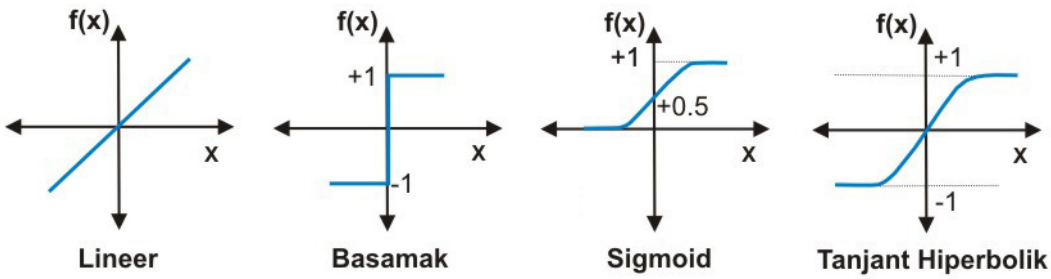
Şekil 3.1 Bir yapay nöronun diyagram olarak gösterimi

Şekil 3.1'de i giriş nöron sayısını, x_i girişleri, w_i x_i girişine ait ağırlığı, s her bir girişe ait ağırlık değerlerinin çarpımının toplamını, $\psi(.)$ *transfer fonksiyonunu*, y ise çıkışı ifade etmektedir. Nöronlar arasındaki bağlantılar *ağırlık* olarak ifade edilen değerler ile karakterize edilir. Ağırlıklar bir nöron'a gelen bilginin önemini ve nöron üzerindeki etkisini belirtir (Baykan 2007). Her bir girişe ait ağırlık değerlerinin çarpımının toplamı olan s değerini oluşturulması θ *eşik değeri* olmak üzere eşitlik 3.1'e göre ve nöronun çıkış değerinin (y) elde edilmesi ise eşitlik 3.2'ye göre gerçekleştirilir (Haykin 1994; Baykan 2007; Tezel 2007)

$$s = \sum_{j=1}^{i} x_j w_j + \theta \tag{3.1}$$

$$y = \psi(s) \tag{3.2}$$

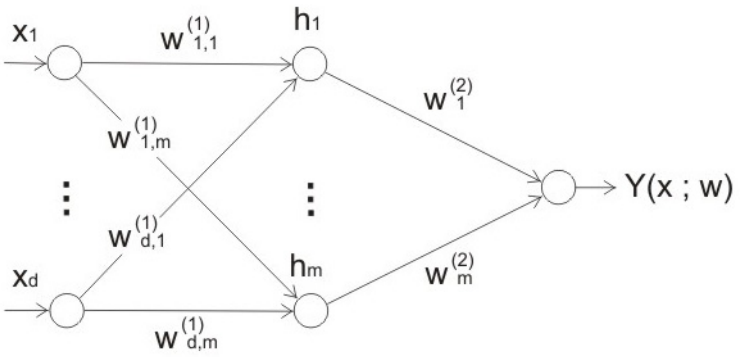
Nöronun çıkışında elde edilen değer; girişleri karakterize eden ağırlıklara, girişe ait ağırlık değerlerinin çarpımının toplamına etki eden eşik değerine ve transfer fonksiyonunun tipine bağlıdır. Transfer fonksiyonları bir nöronun çıkış genliğinin istenilen aralıkta olmasını sağlamak amacıyla kullanılmaktadır. Transfer fonksiyonları türevi alınabilir ve sürekli olmak zorundadırlar. Ancak kullanım amacına göre tek veya çift yönlü olarak kullanılabilirler (Sağıroğlu ve ark. 2003;). Yaygın olarak kullanılan aktivasyon fonksiyonları Şekil 3.2'de verilmiştir.



Şekil 3.2 Yaygın olarak kullanılan transfer fonksiyonları

3.1.1. Çok Katmanlı Yapay Sinir Ağı (ÇKYSA)

Lineer olmayan problemlerin çözümünde kullanılan en yaygın YSA modellerinden biri çok katmanlı yapay sinir ağıdır (ÇKYSA). ÇKYSA modeli bir giriş katmanına, bir ya da daha fazla sayıda gizli katmana ve bir çıkış katmanına sahiptir. Her bir katman ÇKYSA'nın uygulanacağı probleme göre farklı sayıda nöron içerebilir. Bir katmandaki her bir nöron bir önceki katmandaki tüm nöronlara ait ağırlıklandırılmış toplamı almaktan ve bu değeri bir sonraki katmana giriş olarak iletmekten sorumludur (Serhatlıoğlu ve ark. 2003). Gizli katman ya da katmanlara ait nöronlar ile çıkış katmanına ait nöronların çıkış değerleri probleme özel olarak seçilen transfer fonksiyonlarına göre hesaplanır. Bir giriş katmanı, bir gizli katman ve bir çıkış katmanına sahip olan örnek ÇKYSA modelinin yapısı Şekil 3.3'te verilmiştir.



Şekil 3.3 Örnek ÇKYSA modeli

ÇKYSA modeli danışmanlı öğrenme yöntemini kullanmaktadır. Bu modelde ağa hem girişler hemde bu girişlere karşılık gelen beklenen çıkışlar verilmektedir. ÇKYSA modeli, kendisine verilen giriş ve çıkışlara göre ağırlıkları genelleştirerek çözüm uzayını oluşturur. Model, algoritmanın gerçekleştirilmesi aşamasında oluşan

çıkışlara ait hataların en aza indirgenmesi amacıyla yaygın olarak *geriye yayılım* algoritmasını kullanmaktadır (Tezel 2007).

ÇKYSA modeli için geriye yayılım algoritması üç aşamada gerçekleşmektedir. İlk aşamada giriş değerlerine bağlı olarak çıkış değerleri oluşturulur. İkinci aşamada, oluşan bu çıkış değerleri ile beklenen çıkış değerleri arasındaki hata hesaplanır. Son aşamada ise oluşan hatanın en aza indirilmesi amacıyla hata, çıkış katmanından giriş katmanına doğru yayılarak ağırlıkların güncelleştirilmesi sağlanır (Pao 1989; Fausett 1994).

Girişlere bağlı olarak oluşan çıkış değerleri ile beklenen çıkış değerleri arasında oluşacak olan ve geriye yayılma algoritmasında en aza indirgenmesi beklenen hatanın hesaplanması için genellikle eşitlik 3.3'te verilen toplam karesel hata formülü kullanılır.

$$E = \frac{1}{2}\sum_{k=1}^{n}(\bar{y}_k - y_k)^2 \tag{3.3}$$

Burada n çıkış katmanındaki nöron sayısını, y_k beklenen çıkış değerini ve $\bar{y}_k$ elde edilen çıkış değerini belirtmektedir.

Geriye yayılım algoritmasında, tüm girişlerin ağırlıklandırılmış toplamlarının gizli katmanlar üzerinden çıkış katmanına aktarıldığını kabul ettiğimizde *i*. ve *j*. katmanlardaki nöronlar arasındaki ağırlıkların değişikliği $\Delta w_{ij}(t)$ olarak kabul edilirse bu değişim eşitlik 3.4'te verildiği gibi hesaplanabilir.

$$\Delta w_{ij}(t) = \eta \delta_j x_i + \alpha \Delta w_{ij}(t-1) \tag{3.4}$$

Burada $\Delta w_{ij}(t-1)$ iterasyonun bir önceki $(t-1)$ adımında elde edilen *i*. ve *j*. katmanlardaki nöronlar arasındaki ağırlıkların değişim değeridir. η öğrenme katsayısı, α ise momentum katsayısıdır. δ_i değeri çıkış katmanı için eşitlik 3.5'e göre, gizli katmanlar için ise 3.6'ya göre hesaplanır.

$$\delta_j = \frac{\partial f}{\partial net_j}(\bar{y}_j - y_j) \tag{3.5}$$

$$\delta_j = \frac{\partial f}{\partial net_j}(\sum w_{qi}\delta_q) \tag{3.6}$$

$$net_j = \sum x_j w_{ij} \tag{3.7}$$

3.2. Destek Vektör Makinesi (DVM)

DVM yapısal risk minimizasyonu temelinde Vapnik (1995) tarafından geliştirilen bir metottur. İstatistiksel öğrenme temeline dayanan metot sınıflandırma, kümeleme, regresyon, vb. amaçlarla kullanılmaktadır (Vapnik 1995). DVM, örneklerin lineer olarak ayrılabilir olması durumunda sınıflandırma işlemini gerçekleştirebilmektedir. Eğer giriş uzayı lineer değilse, DVM giriş uzayını çeşitli çekirdek fonksiyonları kullanarak yüksek boyutlu özellik uzayına dönüştürmek zorundadır. DVM de en temel amaç iki sınıfı birbirinden ayıran düzlemler içerisinden optimum hiper-düzlemi elde etmektir (Burges 1998; Çomak 2008; Gunn 1998).

3.2.1. Lineer destek vektör makinesi

Eğitme veri kümesindeki her bir verinin *n*-boyutlu bir vektör olduğu ve iki sınıftan sadece birine ait olduğu kabul edildiğinde girişler $(x_1, y_1),...,(x_n, y_n)$, $x \in R^N$ ve çıkışlar da $y \in \{+1,-1\}$ şeklinde ifade edilebilir. İki sınıfı birbirinden ayrılan tüm hiper-düzlemler eşitlik 3.8 ya da genelleştirilmiş formuyla eşitlik 3.9. deki formlara uymak şartı ile elde edilir.

$$\begin{aligned} (w.x_i) + w_0 &\geq +1 - \xi_i, \quad \text{eğer } y_i = +1 \\ (w.x_i) + w_0 &\leq -1 - \xi_i, \quad \text{eğer } y_i = -1 \end{aligned} \tag{3.8}$$

$$y_i\left[(w.x_i) + w_0\right] \geq 1, \qquad i = 1,...,n \tag{3.9}$$

Burada ξ_i küçük hata payı ile bazı verilere tolerans tanımak amacıyla kullanılan serbestlik değişkenleri olmak üzere $\xi_i \geq 0$ 'dır. Eğer tüm eğitme verisi eşitlik 3.8 ya da bu denklemin genelleştirilmiş formu olan eşitlik 3.9'a uyuyor ise ξ_i değişkenleri kullanılmayacaktır. Tüm hiper-düzlemler arasındaki optimum hiper-düzlem eşitlik 3.10'un minimizasyonunun sağlanması ile elde edilir.

$$C\sum_{i=1}^{n}\xi_i + 1/2\|w\|^2 \tag{3.10}$$

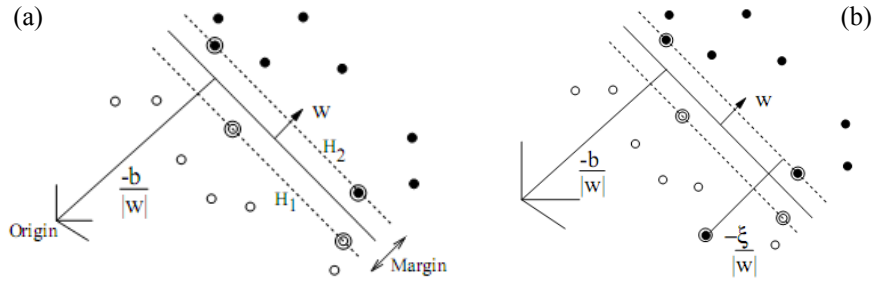
Burada C düzenleme parametresidir ve karmaşıklık ile sınıflandırma performansı arasındaki zıt artış-azalışı ayarlar. Bir başka deyişle, optimum ayırıcı hiper-düzlem Şekil 3.4'teki aralığı maksimum yapan hiper-düzlemdir. Bu yüzden problem, eşitlik 3.11 ve eşitlik 3.12'deki ikinci derece optimizasyon problemi haline dönüştürülür ve amaç eşitlik 3.12'e dayanarak eşitlik 3.11.'in maksimize edilmesidir (Burges 1998).

$$w(\alpha) = \sum_{i=1}^{n}\alpha_i - 1/2\sum_{i,k=1}^{n}\alpha_i y_i \alpha_k y_k (x_i, x_k) \tag{3.11}$$

$$\sum_{i=1}^{n}\alpha_i y_i = 0\,,\ \alpha_i \geq \forall i \tag{3.12}$$

Eşitlik 3.11 ve eşitlik 3.12'de hesaplanan α_i Lagrange çarpanlarına bağlı olarak örneğin sınıfını belirten karar fonksiyonu eşitlik 3.13'da verilmiştir.

$$f(x) = sign\left(\sum_{i=1}^{sv}\alpha_i y_i (x, x_i) + b\right) \tag{3.13}$$



Şekil 3.4 (a) Lineer olarak ayrılabilen ve
(b) Lineer olarak ayrılamayan DVM yapısı örnekleri (Burges 1998)

3.2.2. Lineer olmayan destek vektör makinesi

Lineer olmayan bir özellik uzayı içerisinde DVM optimum hiper-düzlemi bulamamaktadır. Bu durumda, DVM'nin optimum hiper-düzlemi bulabilmesi amacıyla lineer olmayan özellik uzayı çeşitli *çekirdek fonksiyonları* kullanılarak daha yüksek boyutlu lineer özellik uzayına dönüştürülürler. Bu dönüşümde kullanılacak olan çekirdek fonksiyonları eşitlik 3.14'deki gibi ifade edilebilir.

$$K(x,x') = (\Phi(x).\Phi(x')) = \Phi(x)\Phi(x') \tag{3.14}$$

Çekirdek fonksiyonları Mercer'in şartına uymak zorunda olan fonksiyonlardır (Burges 1998). Probleme özel olarak doğru çekirdeğin seçimi sınıflandırma işleminin başarısında oldukça etkilidir. Çekirdek fonksiyonlarına bağlı olarak lineer olmayan DVM'nde eşitlik 3.11 ve eşitlik 3.13'deki ikinci dereceden optimizasyon problemi ve karar fonksiyonuna ait eşitlikler eşitlik 3.15 ve eşitlik 3.16'daki şekle dönüştürülürler.

$$w(\alpha) = \sum_{i=1}^{n} \alpha_i - 1/2 \sum_{i,k=1}^{n} \alpha_i y_i \alpha_k y_k K(x_i, x_k) \tag{3.15}$$

$$f(x) = sign\left(\sum_{i=1}^{sv} \alpha_i y_i K(x, x_i) + b\right) \tag{3.16}$$

En sık kullanılan DVM çekirdek fonksiyonları aşağıdaki gibi sıralanabilir:

- Lineer çekirdekler : $K(x, x') = x.x'$
- Polinomal çekirdekler : $K(x, x') = (x.x' + 1)^d$; d çekirdeğin derecesi olan pozitif tamsayıyı ifade etmekte,
- RBF çekirdekler : $K(x, x') = \exp(-\|x - x'\|^2 / \sigma^2)$; σ pozitif tamsayıyı ifade etmektedir.

DVM temelde iki sınıfa ait örneklerin sınıflandırılmasını gerçekleştirmekle birlikte çok sınıfa ait örneklerin sınıflandırılması, veri kümelerinin çeşitli şekillerde iki sınıflı alt kümelere bölündükten sonra değerlendirilmesi ve ardından da tüm alt kümelerin sınıflandırma sonuçlarının toplu olarak değerlendirilmesi ile gerçekleştirilmektedir (Hsu ve Lin 2002).

3.3. Yapay Bağışıklık Tanıma Sistemi (YBTS)

Bağışıklık sistemi vücuda giren çok sayıdaki yabancı içeriği tanıyarak bu içeriğin doğal ve zararsız içerikten ayırt edilebilmesini sağlayan omurgalı canlıların savunma sistemidir. Yabancı içerik vücuda girdikten sonra bağışıklık sistemi bu yabancı içeriği tanıyacak ve bu içeriği dışarı atmak amacıyla savunma elemanları geliştirecektir. Bağışıklık sisteminin verdiği bu tepkiye bağışıklık tepkisi denir ve sistem, karşılaştığı yabancı içeriği bir kez tanımladıktan sonra sürekli tanıma yeteneğine sahip olur. Dolayısıyla, daha sonra tekrar gelecek aynı tür yabancı içerik için bağışıklık sistemi, bu içeriğe karşı daha hızlı ve etkin bir tepki verecektir (Kodaz 2007).

YBTS yabancı içeriği tanıyarak bu içeriğe karşı bir savunma sistemi oluşturan biyolojik bağışıklık sisteminden esinlenilerek geliştirilmiş bir metottur. Bir başka deyişle, evrimsel bir algoritma olan YBTS, tipik olarak bağışıklık sisteminin problem çözmedeki öğrenme ve hafıza karakteristiklerini kullanan omurgalı canlıların bağışıklık sisteminin ilke ve işlemlerinden esinlenerek Watkins (2001) tarafından geliştirilmiş hesaplanabilir bir metottur.

YBTS'nin amacı sınıflandırılmada kullanılacak olan hafıza hücrelerinin oluşturulmasıdır. Eğitim antijenlerini en iyi sınıflandıracak olan antikorların oluşturulması yapay tanıma topu (YTT) havuzu kullanarak gerçekleştirilir. Bu havuz, eğitme antijenini en iyi sınıflandıracak olan antikor ile daha önce eklenen ve mutasyona uğramış diğer antikorları içermektedir. Bağışıklık sisteminin fizyolojisi ve YBTS ile bağlantılı sistem elemanlarının detaylı tanımına Kodaz'ın (2007) ve Polat'ın (2004) çalışmalarından erişilebileceği gibi YBTS metodunun algoritması aşağıdaki gibi özetlenebilir. Şekil 3.5'de YBTS algoritması için bir diyagram sunulmuştur.

Algoritmada kullanılan önemli terimler ve kavramlar (Polat 2004):

Antikor: Özellik vektörü ile sınıf değerinin birleşiminden oluşan bu değer, yapay tanıma topu ya da hafıza hücresinde kullanıldığı zaman antikor olarak adlandırılır.

Antijen: Antikorla aynı şekilde, özellik vektörü ile sınıf değerinin birleşiminden oluşan bu değer ise eğitim ve test örneklerinin algoritmada temsil edilmesi amacıyla kullanılır.

Yapay tanıma topu (YTT): Bir antikor, bu antikora atanmış kaynakların sayısı ve antikorun o anki uyarma değerini içeren bir sistem elemanıdır.

Duyarlılık: İki antikor ya da antijen arasındaki yakınlığın ya da benzerliğin ölçüsü olarak tanımlanan bu değer [0,1] aralığında sayısal olarak ifade edilmektedir. Uzaklık ölçütleri kullanılarak hesaplanan duyarlılık değeri beklendiği üzere küçük olduğunda ilişkili nesneler arasında güçlü bir duyarlılık olduğunu ifade etmektedir.

Duyarlılık eşiği: Eğitim kümesindeki ya da eğitim kümesinin alt kümesindeki antijenlerin ortalama duyarlılık değeri olarak tanımlanır.

Duyarlılık eşik ölçüsü: Bu değer, duyarlılık eşiği ile çarpıldığı zaman hafıza hücrelerinin yer değişimi için bir eşik değeri oluşturmaktadır.

Mutasyon oranı: Bir YTT'nun özellik vektöründeki herhangi bir özelliğin ya da sınıf değerinin mutasyona uğrama olasılığını belirten [0,1] aralığındaki bir değerdir.

Uyarma eşiği: Bir antijenin eğitimde durma kriteri olarak kullanılan bu değer, YTT havuzundaki ortalama uyarma değerinden büyük olması durumunda eğitimin sonlanmasını sağlar.

Hipermutasyon oranı: Hafıza hücresi havuzunda izin verilecek olan toplam hafıza hücresi sayısının belirlenmesinde kullanılan bir değerdir.

Kaynak: Sistemde izin verilen YTT'larının sayısını belirleyen bir değerdir. Uyarma değeri ve klonlama oranı kullanılarak her bir YTT'na toplam ayrılmış kaynak sayısı paylaştırılır. Kaynak sayısı izin verilen değerden fazla ise bu değerin sağlanması amacıyla kaynak düzenlenmesi tekrar gerçekleştirilir ve kaynak ayarlanmasının ardından kaynak değeri 0 olan bir kaynak YTT havuzundan çıkartılır.

Klonlama oranı: YTT'nun mutasyona uğrayarak çeşitlendirilmesi aşamasında oluşturulacak olan klon sayısını belirlemede kullanılan bir değerdir. Algoritmada, klonlama oranı ile uyarma değerinin çarpımı kadar mutasyona uğramış klon oluşturulmasına izin verilir. Bu değer aynı zamanda YTT'ları için kaynak tahsisinde de kullanılır.

Hafıza hücresi: Eğitim antijeni tarafından en fazla uyarılan YTT'dur. Algoritmanın sonlanması aşamasında hafıza hücrelerinden oluşan hafıza hücresi havuzu test kümesinin sınıflandırılmasında kullanılmaktadır.

YBTS algoritması:

1. Başlangıç :

Veri kümesinin normalizasyonu bu aşamada gerçekleştirilir. Probleme özel olarak belirlenen *mutasyon oranı*, *hipermutasyon oranı*, *duyarlılık ölçüsü*, *duyarlılık eşik ölçüsü*, *uyarma eşiği*, *klonlama oranı* ve *kaynak sayısı* gibi YBTS parametreleri bu aşamada belirlenir.

2. YTT havuzunun oluşturulması :

YTT havuzunun oluşturulmasındaki amaç algoritmanın sonunda elde edilecek ve sınıflandırma amacıyla kullanılacak olan hafıza hücreleri havuzunun genelleştirilmesini ve mevcut antikor çeşitliliğini artırmaktır. Bu aşamada, hafıza hücreleri içerisindeki eğitim antijeni ile en iyi uyarma eşik değerine sahip olan eşlenik antikor bulunur. Bu antijene *uygun hafıza hücresi* (UHH) adı verilir ve UHH mutasyona uğratılarak YTT havuzuna eklenir. UHH'nin mutasyona uğradıktan sonraki YTT havuzuna eklenecek mutasyon klon sayısı eğitim antijeni ile UHH arasındaki eşik değeri, hipermutasyon oranı ve klonlama oranının çarpımına eşit olarak belirlenir.

3. YTT havuzunun geliştirilmesi :

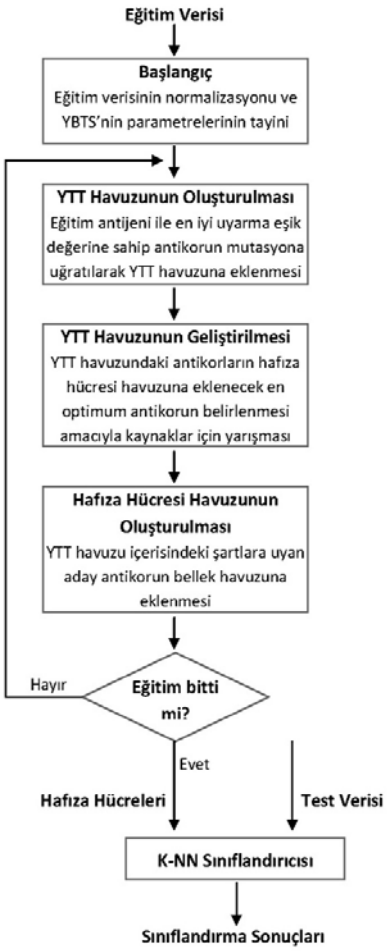
Bu aşamada kaynak dağıtımının gerçekleştirilmesi ile YTT havuzundaki eğitim antijenini iyi sınıflandıran antikorların daha yüksek kaynak değerine sahip olmasını, kötü sınıflandıran antikorların da daha düşük kaynak değerine sahip olmasını sağlayarak havuzda iyi kaynak değerine sahip antikorların sürekliliğini ve çeşitlendirilmesini, kötü kaynak değerine sahip antikorların da YTT havuzundan çıkartılmasını sağlamak amaçlanmaktadır. Buna göre, YTT havuzundaki her bir antikora ait olan kaynak sayısı klonlama oranı ve her bir antikorun eşik değerine göre belirlenmiştir. YTT havuzundaki tüm antikorlar mutasyon durma kriterine göre (bu kriter genellikle belirli sayıdaki klonun oluşturulması olarak alınır) mutasyona uğratılır.

4. Hafıza Hücresi Havuzunun Oluşturulması :

Bu aşama, YTT havuzunda geliştirilen antikorlar ile hafıza hücresi havuzundaki mevcut antikorların sınıflandırmada kullanılacak temel antikorları oluşturması amacıyla gerçekleştirilen bir aşamadır. YTT havuzundaki eğitim antijeni ile en iyi uyarma eşik değerine sahip antikor hafıza hücresi havuzuna aktarılmak üzere değerlendirilir ve aynı zamanda bu antikor aday antikor adını alır. Eğer, aday antikor ile eğitim antijeni arasındaki uyarma eşik değeri aday antikor ile UHH'nden büyük ise aday antikor hafıza hücresi havuzuna eklenir. Eğer ekleme gerçekleşmişse UHH'nin hafıza hücresi havuzundaki mevcudiyeti kontrol edilmelidir. Burada, eğer aday antikor ile UHH arasındaki uyarma eşik değeri duyarlılık eşik ölçüsü ile duyarlılık ölçüsünün çarpımından küçükse UHH hafıza hücresi havuzundan çıkartılır.

5. Sınıflandırma :

Tüm eğitim antijenleri için 2, 3 ve 4. aşamalar tekrarlanır. Eğitim işlemi tamamlandıktan sonra oluşan hafıza hücresi havuzu artık sınıflandırma için kullanılacak olan antikorları saklamaktadır. Hafıza hücresindeki antikorlar kullanılarak test kümesi K-NN gibi bir yöntem yardımıyla sınıflandırılır.



Şekil 3.5 YBTS algoritmasının adımları

3.4. K-En Yakın Komşu (K-NN)

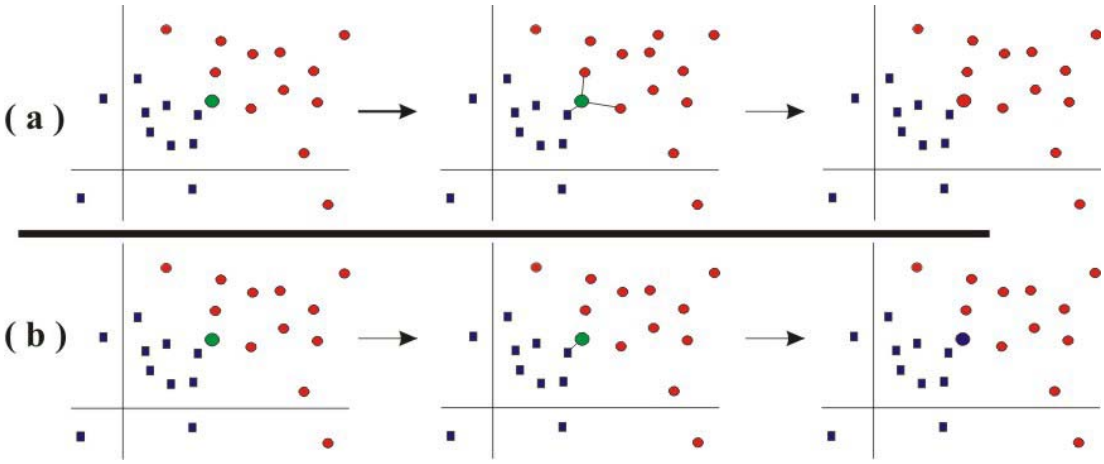
K-NN yaygın olarak kullanılan temel sınıflandırma metotlarından birisidir. Uygulaması basit ve hesaplama maliyeti oldukça düşük olan bu algoritma, sınıflandırılacak verinin dağılımı hakkında çok az ya da hiçbir bilgiye sahip olunamaması durumunda ilk tercih olarak seçilebilecek metotlardan biridir. K-NN, olasılık yoğunluklarının güvenilir parametrik değerlendirmelerinin bilinmediği ya da tahmininin zor olduğu durumlarda diskriminant analizinin gerçekleştirilmesi amacıyla geliştirilmiştir (Duda ve ark. 2001; Shakhnarovish ve ark. 2005).

K-NN algoritması çoğu sınıflandırma metodundan farklı olarak eğitme aşamasına sahip olmamasından dolayı oldukça hızlı bir metottur. Bu metotta *j*-boyutlu özellik uzayında sınıflandırılacak her test örneği için Öklid, Hamming, Manhattan, vb. uzaklık ölçüm yöntemleri kullanılarak en yakın *k* örnek eğitim kümesi olarak belirlenen küme içerisinden belirlenir. Sınıflandırılacak örneğin sınıfı elde edilen en yakın *k* örneğin çoğunluk oylamasında değerlendirilmesi ile elde edilir (Pal ve ark. 2004; Duda ve ark. 2001). Bir başka deyişle, sınıflandırılacak örneğin sınıfı elde edilen en yakın k örneğin ait olduğu sınıflardan en çok tekrar edeni olarak kabul edilir. K-NN metodunda yaygın olarak kullanılan Öklid uzaklık ölçüm yönteminin hesaplanma şekli eşitlik 3.17'te verilmiştir.

$$d = \sqrt{\sum_{i=1}^{n} (p_i - q_i)^2} \tag{3.17}$$

Burada p sınıflandırılacak yeni örneği, q eğitim kümesindeki herhangi bir örneği, n örneklerin özellik sayısını, i ise özelliğin p ve q içerisindeki indeksini belirtmektedir.

İki sınıfa ait örneklerin bulunduğu 2 boyutlu özellik uzayında K-NN algoritmasının 1 ve 3 komşuluk için (k=1 ve k=3) yeni bir test örneğini sınıflandırmasına ilişkin gösterim Şekil 3.6'da verilmiştir. Şekil 3.6(a)'da belirtilen yeni örnek kendisine en yakın komşu olan 3 örneğini baskın sınıfına dahil edilmişken, Şekil 3.6(b)'de komşuluk 1 olduğu için kendisine en yakın örneğin sınıfına dahil edilmektedir.



Şekil 3.6 Örnek bir veri kümesi için yeni örneğin K-NN metodu ile sınıflandırılması; **k**=3 komşuluk için sınıflandırma (a), **k**=1 komşuluk için sınıflandırma (b)

3.5. Parçacık Sürü Optimizasyonu ve K-En Yakın Komşu Tabanlı Karma Algoritma (PSO-K-NN)

GA'ya benzer bir algoritmaya sahip evrimsel bir algoritma olan PSO Bölüm 4.2'de detaylıca anlatılmaktadır. Tez çalışmasında PSO'nun K-NN algoritmasıyla birlikte sınıflandırma amacıyla kullanıldığı karma bir algoritma (PSO-K-NN) kullanılmıştır. Bu karma algoritmada temel amaç eğitme kümesi kullanılarak veri kümesinde bulunan sınıfları temsil edecek optimum merkezi (centroid) vektörlerin PSO kullanılarak bulunması ve daha sonra da 1 komşuluk değerli (k=1) K-NN yöntemi ile test kümesinin sınıflandırılmasıdır.

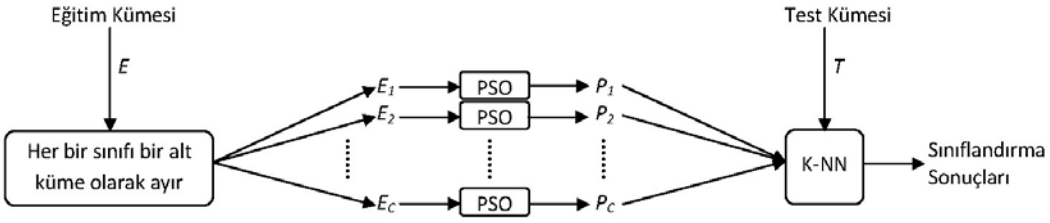
PSO ile gerçekleştirilen bu sınıflandırma işleminde n boyutlu C adet sınıfa sahip veri kümesi C adet altkümeye ayrılmaktadır. Birbirinden farklı ve eğitim kümesi içerisindeki her sınıfın örneklerini en iyi şekilde temsil edebilecek olan C adet optimum merkezi vektör temel PSO yöntemi kullanılarak elde edilmektedir. Buna göre PSO yöntemi kullanılarak elde edilen n boyutlu C adet optimum merkezi vektör ve bu vektöre ait hızlar eşitlik 3.18 ve eşitlik 3.19'deki gibi ifade edilebilir (De Falco ve ark. 2006).

$$X_i = (x_i^1, x_i^2, ..., x_i^N) \tag{3.18}$$

$$V_i = (v_i^1, v_i^2, ..., v_i^N) \tag{3.19}$$

Burada, i sınıf indeksi olmak üzere $1 \le i \le C$, X parçacık ve V de parçacığın hızını belirtir. Optimum merkezi vektörlerin bulunması aşamasında kullanılan PSO yönteminde uygunluk fonksiyonu Öklit uzaklığı gibi bir uzaklık fonksiyonu şeklinde kullanılır. Böylece her sınıfa ait eğitim kümesi için o kümeyi en iyi örnekleyecek optimum merkezi vektör, kümenin tüm elemanlarına en yakın optimum merkezi vektör olarak elde edilir.

Eğitim kümesi içerisinden PSO kullanılarak C sınıfa ait C adet optimum merkezi vektör elde edildikten sonra test kümesindeki örnekler bu merkezi vektörler ile K-NN yöntemi kullanılarak sınıflandırılırlar. Buna göre, test kümesindeki örnek hangi merkezi vektöre daha yakınsa o merkezi vektörün elde edildiği sınıfa dahil edilir. E eğitim kümesi, T test kümesi ve P'de optimum merkezi vektör olmak üzere algoritmanın genelleştirilmiş bir diyagramı Şekil 3.7'te verilmiştir.



Şekil 3.7 PSO-K-NN Algoritması

4. ÖN İŞLEME VE ÖZELLİK SEÇİMİ AMACIYLA KULLANILAN ALGORİTMALAR

4.1. Genetik Algoritma (GA)

Uzun süren gözlemleri sonunda Darwin evrim teorisini öne sürmüştür. Bu teoriye göre yaşayan canlılar hayatta kalmak amacıyla birbirleriyle mücadele etmektedirler. Bu mücadelenin sonunda başarılı bireyler genlerini bir sonraki nesle transfer ederler (Gestal ve Andrade 2008).

Darwin'in evrim teorisinden esinlenen GA tekrarlı ve eğitimli bir yarışmacı model olarak ilk defa Holland (1975) tarafından geliştirilmiştir. Genellikle ayrık ya da sürekli değerler alan optimizasyon problemlerinde kullanılan GA'nın temel amacı potansiyel veri kümesi içerisinden optimum çözüme ya da çözümlere ulaşmaktır.

GA'da her bir çözüm kümesi *popülasyon* olarak adlandırılır. Popülasyonlar *kromozom* ya da *birey* adı verilen vektörlerden oluşurlar ve bir vektör içerisindeki her bir parçaya *gen* adı verilir. Temel olarak bir GA şu şekilde çalışır: Başlangıçta bir çözüm popülasyonu rastgele bir biçimde oluşturulur ve oluşan bu çözümler ardışık çaprazlama ve mutasyon aşamalarının ardından sürekli olarak gelişir. Popülasyondaki her bir kromozomun problemi çözme yeterliliğine uygun olarak, bireyin uyarlama ve uygunluk açısından kullanışlığını derecelendiren kendisine ait bir değeri vardır. Bu değer her bir potansiyel çözüm için elde edilmesi gerekli olan bir değer olup araştırmaya yön verilmesinde kullanılacak evrimsel algoritmanın sayısal bilgisini oluşturmaktadır. İşlem, ön tanımlı bir durma kriterine erişilinceye kadar devam eder. Bu kriter elde edilen çözümün hatasına ait bir eşik değeri ya da belirli sayıdaki iterasyon olabilir (Gestal ve Andrade 2008). Buna göre GA'nın yapısı Şekil 4.1.'de verilmiş olup aşamaların detaylı anlatımı aşağıdaki şekilde gerçekleştirilebilir (Holland 1975; Michalewicz 1992):

Başlangıç :

Algoritmanın başında, potansiyel çözüm kümesi içerisindeki bir çözümü içeren her bir kromozom ikili değerlerden rastgele bir şekilde oluşturulur.

Değerlendirme :

GA ile optimizasyon işleminde, kromozomların problemi çözme yeterliliği belirten bir değer uygunluk fonksiyonu adı verilen değerlendirme fonksiyonu kullanılarak potansiyel çözüm kümesi içerisindeki her bir kromozom için hesaplanır. GA'nın başarısını etkileyecek en önemli faktörlerin başında uygunluk fonksiyonunun seçilmesi bulunmaktadır. Bu yüzden uygunluk fonksiyonu çözüme odaklanmış olarak etkin bir biçimde seçilmelidir.

Seleksiyon :

Bu aşama uygunluk değerlerine bağlı olarak kromozomların genlerini bir sonraki nesle aktarılmasını sağlamak amacıyla uygun kromozomların seçilmesini amaçlamaktadır. Sözü geçen bireylerin seçilme işlemi *rulet tekeri*, *derecelendirme*, *kararlı hal*, *elitizm* vb. seçim tekniklerinden biri kullanılarak gerçekleştirilir. Geleneksel GA'da en yaygın kullanılan teknik rulet tekeri seçim tekniğidir. Bu seçim tekniğine göre popülasyondaki tüm kromozomların seçilme şansı küçük de olsa mevcuttur. Burada, her bir kromozom uygunluk değerine göre rulet tekerinin üzerinde bir pay alır ve bu payın değerinin hesaplanması eşitlik 4.1'e göre gerçekleştirilir. En yüksek uygunluk değerine sahip olan kromozom en büyük paya ve en düşük uygunluk değerine sahip olan kromozom en küçük paya sahip olmak üzere tüm kromozomlara verilen payların toplamı 1'e eşittir. Oluşturulan bu rulet tekerinden bir kromozomun seçilme olasılığı teker üzerindeki payı ile doğru orantılıdır.

$$P(c_i)=\frac{f_i}{\sum_{j=1}^{N} f_i i} \tag{4.1}$$

Burada c_i rulet tekerinde pay alacak bireyi, f_i söz konusu kromozomun uygunluk değerini, N ise popülasyondaki kromozom sayısını belirtmektedir.

Yaygın olarak kullanılan rulet tekeri seçim tekniğinin aksine, derecelendirme seçim tekniği uygunluk değeri düşük de olsa her kromozoma daha fazla seçim hakkı tanır. Bu teknikte, popülasyondaki N adet kromozom uygunluk değerlerine göre değil de en kötü uygunluk değerine sahip olandan en yüksek uygunluk değerine sahip olana doğru sırasıyla $1,2,...,N-1,N$ değerlerini alırlar. Böylece aşırı yüksek ya da aşırı düşük de olsa kromozomların seçim şansı rulet tekeri seçim tekniğine göre artırılmış olur.

Kararlı hal seçim tekniği ise kromozomları seçmek için kullanılan bir metot olmaktan ziyade popülasyonun başarısını kararlı tutmayı amaçlayan genel bir işleyiştir. Bu tekniğe göre, her bir iterasyonda popülasyonun belirlenen sayıdaki en kötü kromozomların çıkartılarak yerlerine eşit sayıdaki en iyi kromozomların eklenmesi sağlanır.

Elitizm tekniği, kararlı hal seçim tekniğine benzer şekilde çalışır. Bu tekniğin temel amacı iterasyon boyunca elde edilen en iyi uygunluk değerine sahip kromozomları kaybetmemektir. Popülasyondan çıkartılan belirli sayıdaki kromozomların yerine iterasyon boyunca elde edilen en iyi uygunluk değerine sahip kromozomlar eklenir.

Çaprazlama :

Yeni nesilde bulunacak olan kromozomların çeşitliliğini artırmak amacıyla gerçekleştirilen bu aşama ön tanımlı bir *çaprazlama oranı*na bağlı olarak popülasyon içerisinden rastgele seçilen kromozom çiftlerinin çaprazlanması şeklinde gerçekleştirilir. Bir başka değişle çaprazlama, kromozom çiftlerinin rastgele seçilen bir ya da daha fazla geninin yer değiştirmesi olarak tanımlanabilir.

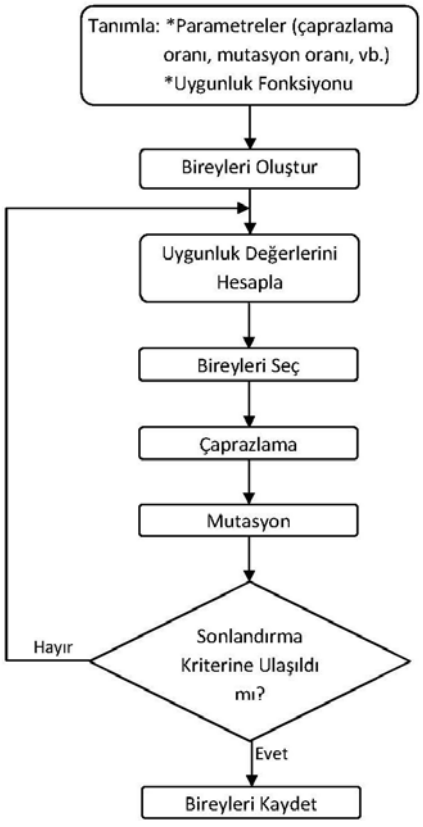
Mutasyon :

Mutasyon aşaması da popülasyonun çeşitliliğini artırmak amacıyla gerçekleştirilen bir aşamadır. Çaprazlama işleminde çeşitliliğin artırılmaya çalışılması mevcut kromozomlar kullanılarak gerçekleştirilirken mutasyon işlemindeki çeşitliliğin artırılmaya çalışılması popülasyondaki bir kromozomu kullanarak popülasyona hiç dahil edilmemiş genlere sahip bir kromozomun oluşturulması yolu ile gerçekleştirilir. Mutasyon işlemi, belirlenen *mutasyon oranı*na

bağlı olarak rastgele seçilen kromozom ya da kromozomların genlerinin ikili değerlere göre mevcut değerinin tersini alacak şekilde değiştirilmesi şeklinde gerçekleştirilir.

Sonlandırma :

Sonlandırma işlemi, belirlenen bir kritere bağlı olarak GA'nın seleksiyon, çaprazlama ve mutasyon işlemlerinin iteratif olarak devam etmesinin sonlandırmasını kontrol eden bir işlemdir. Bu kritere göre GA belirli bir iterasyon sayısınca çalıştırılabilir ya da beklenen uygunluk değerine erişilmesi ile sonlandırılabilir.



Şekil 4.1 GA'nın yapısal gösterimi

4.2. Parçacık Sürü Optimizasyonu (PSO)

PSO, Kennedy ve Eberhart (1995) tarafından geliştirilmiş bir algoritmadır. Günümüzde kullanılan pek çok evrimsel algoritmanın gelişmesine benzer şekilde kuş ve balıkların sürü halinde hareket etmesini modelleyerek geliştirilen bu algoritmanın ilk sunumu 1995 yılında gerçekleştirilmiştir. GA'ya da oldukça benzeyen PSO, ilk olarak YSA'daki ağırlıkların optimizasyonu amacıyla kullanılmıştır (Kennedy ve Eberhart 1995; Sangwook ve ark. 2008). Algoritma, temel matematik operatörlerinin bilgisini gerektirmesi ile birlikte düşük bellek gereksinimi ve yüksek hıza sahip olması nedeniyle uygulanması oldukça basittir. PSO, reel sayılar üzerinde optimizasyon gerçekleştirdiği salt şekli ve ikili sayılar üzerinde optimizasyon gerçekleştirdiği ikili parçacık sürü optimizasyonu (İPSO) şekli ile iki modelde incelenebilir.

PSO tekniğinde her potansiyel çözüm bir parçacık olarak ifade edilir. j-Boyutlu özellik uzayında her parçacık pozisyonlara ($x_{i,j}$) ve hızlara ($v_{i,j}$) sahiptir. Parçacıkların oluşturduğu çözüm kümesine ise sürü adı verilir. Algoritmanın başlangıcında her bir parçacık çözüm uzayından rastgele değerler alarak oluşturulur. Her bir parçacığın başarısı probleme özel olarak belirlenen bir uygunluk fonksiyonu'na göre hesaplanır. İterasyon boyunca, her bir parçacığın oluşturduğu en iyi örnek lokal en iyi parçacık ($P_{best_{i,j}}$) ve sürüdeki herhangi bir parçanın oluşturduğu sürünün en iyi örneği ise global en iyi parçacık ($G_{best_{i,j}}$) olarak saklanır. Her bir iterasyonda, her bir parçacığın hızı ve pozisyonu eşitlik 4.2 ve eşitlik 4.3'e göre güncelleştirilir (Kennedy ve Eberhart 1995).

$$v_{i,j}(t+1) = \omega v_{i,j}(t) + c_1 R_1 (p_{best_{i,j}} - x_{i,j}(t)) + c_2 R_2 (g_{best_{i,j}} - x_{i,j}(t)) \tag{4.2}$$

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1) \tag{4.3}$$

Burada, *i* parçacığın indeksini, *j* parçacığın pozisyonun indeksini, *t* iterasyon değerini ve $v_{i,j}$ *i*. parçacığın *j*. pozisyonunun hızını belirtmektedir. R_1 ve R_2 ise [0,1] aralığındaki düzenli dağılım içerisinden seçilmiş rastgele iki katsayıdır. Bu katsayılar algoritmanın rastgeleliğini sağlayan katsayılardır. c_1 ve c_2 katsayıları eğilim katsayıları, ω ise atalet ağırlığı olarak adlandırılır.

PSO'da, parçacığın hızını kontrol etmek amacıyla v_{mak} ve $v_{\min}$ olarak adlandırılan iki sınırlandırıcı parametre kullanılmaktadır. Bu parametreler hızın değişimini sınırlandırmakta, dolayısıyla çözümlerden çok hızlı bir şekilde uzaklaşılmasını ve olası daha iyi çözümlerin göz ardı edilmemesini sağlamayı amaçlamaktadır. Buna göre, iterasyon boyunca herhangi bir parçacığın herhangi bir hücresine karşılık gelen hız, hızın kabul edilebilir minimum değeri olan $v_{\min}$'den küçükse $v_{\min}$ olarak, hızın kabul edilebilir maksimum değeri olan v_{mak}'dan büyükse v_{mak} olarak kullanılmaktadır.

PSO'nun yapısal gösterimi Şekil 4.2'de verilmiş olup algoritmanın gerçekleştirilmesinde uygulanan adımlar sadeleştirilmiş bir biçimde aşağıdaki gibi özetlenebilir (Shi 2007);

1 – *j*-Boyutlu özellik uzayında her bir parçacığı rastgele pozisyonlara sahip olarak oluştur

2 – Sürüdeki her parçacık için a ve d arası adımları tekrarla

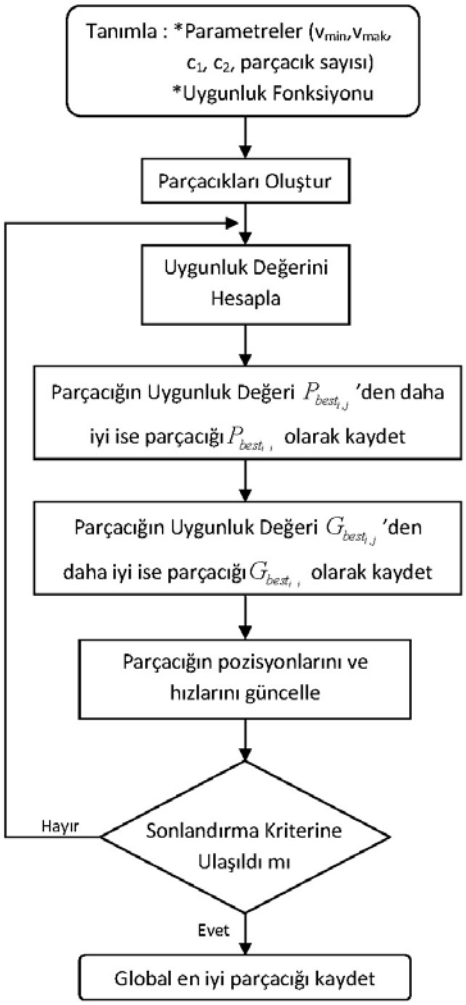
a – Parçacığın başarısını uygunluk fonksiyonunu kullanarak hesapla

b – Eğer işlenen parçacığın başarısı o parçacığa ait lokal en iyi parçacığın ($P_{best_{i,j}}$) başarısından daha iyi ise parçacığı, lokal en iyi parçacık olarak ($P_{best_{i,j}}$) kaydet

c – Eğer işlenen parçacığın başarısı sürünün global en iyi parçacığının ($G_{best_{i,j}}$) başarısından daha iyi ise parçacığı, global en iyi parçacık olarak ($G_{best_{i,j}}$) kaydet

d – eşitlik 4.2 ve eşitlik 4.3'ü kullanarak işlenen parçacığın hız ve pozisyonlarını güncelle

3 – İterasyon sona erene ya da durma kriterine erişilene kadar 2. adımı tekrarla.



Şekil 4.2 PSO'nun yapısal gösterimi

PSO algoritmasının temel amacı, her bir parçacığın iterasyon boyunca oluşturduğu lokal en iyi parçacıktan ve aynı zamanda sürüdeki tüm parçacıkların iterasyon boyunca oluşturduğu global en iyi parçacıktan daha iyi uygunluk değerine sahip olmak amacıyla güncelleştirilmesidir. R_1 ve R_2 katsayıları parçacıkların güncelleştirilmesinin rastgeleliğini sağlamaktadır. Atalet ağırlığı ise güncelleştirmenin ivmesini kontrol ederek çözümün lokal ve global çözümlere

takılmasını engellemeyi amaçlamaktadır.

Atalet ağırlığı Kennedy ve Eberhart (1995) tarafından geliştirilen orijinal PSO algoritmasına ilk defa 1998 yılında Shi ve Eberhart (1998a;1998b) tarafından eklenmiştir. Güncelleştirilmenin ivmesini kontrol eden bu parametre, çözümün lokal ve global çözümlere takılmasını engellemek amacıyla kullanılmaktadır. Shi ve Eberhart'ın (1998a;1998b) çalışmalarında belirtildiği üzere yaygın olarak atalet ağırlığı eşitlik 4.4'e bağlı olarak kullanılmaktadır.

$$\omega = \frac{t_{\max} - t}{t_{\max}} \tag{4.4}$$

Eşitlik 4.4'den de görüleceği üzere atalet ağırlığı, iterasyon boyunca (1,0) aralığında azalan bir eğilim ile değer almaktadır.

c_1 ve c_2 katsayıları yeni parçacıkların, lokal ve global çözümlere yönelmesini sağlamak amacıyla kullanılmaktadır. Literatürde PSO alanındaki geçmiş çalışmaların nerdeyse tamamında c_1 ve c_2 eğilim katsayılarının her ikisinin de 2 olarak kullanıldığı gözlemlenmiştir.

4.2.1. İkili parçacık sürü optimizasyonu

İPSO, ilk defa PSO'nun geliştiriricileri olan Kennedy ve Eberhart (1997) tarafından sunulmuştur. GA'ya benzer şekilde çalışan İPSO da ikili optimizasyon problemlerinin çözümlerinde etkin bir biçimde kullanılabilmektedir. PSO'dan farklı olarak parçacığın pozisyonuna ait değerler reel sayılardan değil de ikili değerlerden oluşmaktadır. İPSO'da parçacığın herhangi bir konumunun 0 ya da 1 olmasının olasılığı parçacığın konumuna ait hızın *sigmoid* fonksiyonu yardımı ile değerlendirilmesiyle gerçekleştirilir. Parçacığın pozisyonunun güncelleştirilmesi eşitlik 4.5'e göre gerçekleştirilir.

$$x_{i,j}(t+1) = \begin{Bmatrix} 0 & if & rand() & >= & S(v_{i,j}(t+1)) \\ 1 & if & rand() & < & S(v_{i,j}(t+1)) \end{Bmatrix} \quad (4.5)$$

Burada, *rand()* fonksiyonu [0,1] aralığındaki düzenli dağılım içerisinde rastgele değer üreten bir fonksiyon, $S(.)$ ise eşitlik 4.6'de verilen sigmoid fonksiyondur.

$$S(v_{i,j}(t+1)) = \frac{1}{1+e^{-v_{i,j}(t+1)}} \quad (4.6)$$

4.3. Ayrıklaştırma

Ayrıklaştırma sürekli değerli niteliklerin ayrık değerler alan benzer parçalara bölünmesi işlemidir. Genellikle ön işleme adımı olarak kullanılan bu işlem, veri kümesinin nümerik analizinde ve özellikle yapay zeka ve makine öğrenmesi algoritmalarında daha etkin işlenmesi amacıyla gerçekleştirilmektedir (Dougherty ve ark. 1995; Hsu ve ark. 2003). Ayrıklaştırma metotları farklı gereksinimleri karşılamak amacıyla çeşitli modellerde geliştirilmiştirler. Buna göre bir ayrıklaştırma metodu *danışmanlı* ya da *danışmansız*, *dinamik* ya da *statik*, *global* ya da *lokal*, *bölünen* ya da *birleşen*, ve *doğrudan* ya da *değişen* olabilir.

Eğer ayrıklaştırma veriyi işlerken örneklerin sınıf bilgisini de kullanıyorsa danışmanlı ayrıklaştırma, kullanmıyorsa danışmansız ayrıklaştırma olarak adlandırılır. Verinin düzenli dağılımın içinde olmadığı durumlarda danışmansız ayrıklaştırma daha kötü sonuçlar vermektedir.

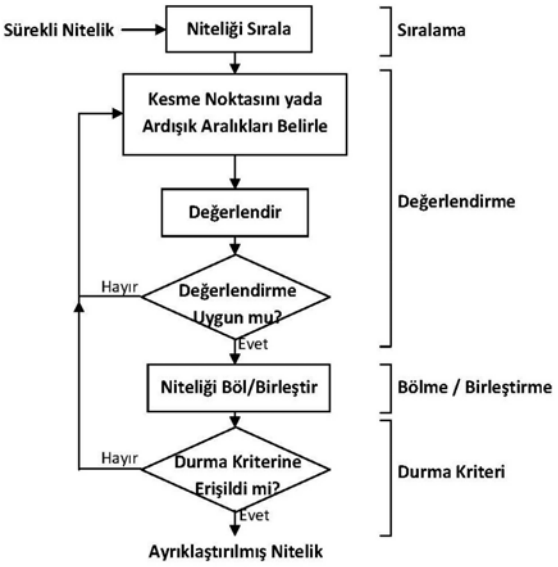
Sınıflandırma algoritmalarının çalışması esnasında algoritmanın bir parçası olarak görev yapan ayrıklaştırma dinamik ayrıklaştırma olarak adlandırılır. Statik ayrıklaştırma, dinamik ayrıklaştırmanın aksine sınıflandırma işleminin öncesinde bir ön işleme olarak ayrı bir biçimde kullanılan ayrıklaştırmadır.

Veri kümesi içerisindeki belirli bir kısım örnek uzayının ayrıklaştırılması lokal ayrıklaştırma olarak adlandırılır. Lokal ayrıklaştırma modelleri genellikle dinamik ayrıklaştırma modelleridir. Veri kümesinin tamamının kullanıldığı ayrıklaştırmaya ise global ayrıklaştırma adı verilir.

Ayrıklaştırmanın bölünen ya da birleşen ayrıklaştırma olması ise kesme noktalarının tayinleri ile gerçekleşmektedir. Bölünen ayrıklaştırma modellerinde, boş bir kesme noktaları listesi ile başlayarak veri kümesi bölündükçe yeni kesme noktalarının listeye eklenmesi ile ayrıklaştırma gerçekleştirilir. Birleşen ayrıklaştırma modellerinde ise veri kümesindeki her bir örneğin değeri varsayılan bir kesme noktası olarak kabul edilir ve algoritma boyunca aralıkların birleştirilmesi sonucunda bazı kesme noktalarının listeden çıkartılması ile ayrıklaştırma gerçekleştirilir.

Doğrudan ayrıklaştırma modellerinde veri kümesi kullanıcının verdiği ek bir bilgiye göre belirlenen sayıdaki aralığın oluşturulması ile ayrıklaştırma işlemi gerçekleştirilir. Değişen ayrıklaştırma modellerinde ise ayrıklaştırma işlemi basit olarak başlar ve belirlenen bir sonlandırma kriterine ulaşılıncaya kadar veri kümesi alt parçalara ayrılır (Liu ve ark. 2002).

Tipik bir ayrıklaştırma işleminin adımları Şekil 4.3'deki gibi verilebilir. Buna göre sürekli değerli nitelikler öncelikle sıralanır. Daha sonra sıralanan bu değerleri bölecek olan aday kesme noktaları belirlenir. Aday kesme noktalarının seçilmesinin ardından bu noktaların kullanılacak olan kesme noktası olup olmadığının tespiti için aday kesme noktalarının uygunluğu hesaplanır. Durma kriteri sağlanana kadar kesme noktalarının elde edilmesine ve bu noktalar ile niteliklerin ayrıklaştırılmasına devam edilir.



Şekil 4.3 Tipik ayrıklaştırma işleminin adımları

Aday kesme noktalarının uygunluğunun belirlenmesi ve durma kriterinin seçilmesine göre ayrıklaştırma modeli çeşitlenecektir. Çalışmalarda hızlı olması, hesaplama maliyetinin az olması nedeniyle ya da sınıflandırma başarısını artırdığının bilinmesi sebebiyle en yaygın kullanılan ayrıklaştırılma modelleri eşit-frekansa dayalı, eşit-aralığa dayalı ve entropi tabanlı ayrıklaştırmadır.

4.3.1. Eşit-aralığa dayalı ayrıklaştırma

Bu ayrıklaştırma modelinde her bir nitelik eşit boyuttaki k adet aralığa bölünerek ayrıklaştırma işlemi gerçekleştirilir. Burada özelliğin en yüksek ve en düşük değerlerinin sırasıyla H ve L olduğu kabul edildiğinde k değerine bağlı olarak aralığın genişliği (W) eşitlik 4.7'ye göre hesaplanır ve kesme noktaları eşitlik 4.8'deki gibi elde edilebilir.

$$W=(H-L)/k \tag{4.7}$$

$$L+W,L+2W,L+3W,...,L+(k-1)W \tag{4.8}$$

4.3.2. Eşit-frekansa dayalı ayrıklaştırma

Eşit-frekansa dayalı ayrıklaştırma modeli eşit-aralığa dayalı ayrıklaştırma modeline benzer şekilde niteliklerin ayrıklaştırma işlemini gerçekleştirmektedir. Eşit-aralığa dayalı ayrıklaştırma modelinde genişliğin boyutu sabit tutulmak istenirken eşit-frekansa dayalı ayrıklaştırma modelinde ise, adından da anlaşılacağı üzere, kesme noktaları arasındaki nitelik sayısının belirlenen bir *k* sayısına ve birbirlerine eşit olmasının sağlanması amaçlanmaktadır.

4.3.3. Entropi tabanlı ayrıklaştırma

En sık kullanılan ayrıklaştırma modeli olan entropi tabanlı ayrıklaştırma yöntemi Fayyad ve Irani (1993) tarafından geliştirilmiştir. Entropi tabanlı ayrıklaştırma modeli niteliğin sınıfına bağlı olarak ayrıklaştırma işlemini gerçekleştirmektedir. Buna göre sürekli değerli bir nitelik için aday kesme noktaları belirlenir. Belirlenen aday kesme noktalarının uygunluk değerleri eşitlik 4.9 ve eşitlik 4.10'a göre hesaplanır.

$$E(A,T;S)=\frac{|S_1|}{|S|}Ent(S_1)-\frac{|S_2|}{|S|}Ent(S_2) \tag{4.9}$$

$$Ent(S) = -\sum_{i=1}^{Z} p(C_i, S)\log_2(p(C_i, S)) \tag{4.10}$$

Burada A ayrıklaştırılacak niteliği, T aday kesme noktasını, S örneklerin kümesini, S_1 ve S_2 ayrıklaştırılmış S kümesinin sırasıyla sağ ve sol alt kümesini, Z veri kümesindeki sınıf sayısını, C_i i. sınıfın karar (sınıf) değerini, $p(C_i, S)$ ise C_i sınıfında bulunan örnek sayısını belirtmektedir.

Uygunluk değeri minimum olan aday kesme noktası seçilerek ayrıklaştırma işlemi özyinelemeli olarak gerçekleştirilir. Entropi tabanlı ayrıklaştırma metodu eşitlik 4.11, eşitlik 4.12 ve eşitlik 4.13'de verilen ve durma kriteri olarak kabul edilen kazanç formülünün sağlanmasına göre sonlandırılır.

$$Kazanç(A,T;S) > \frac{\log_2(N-1)}{N} + \frac{\Delta(A,T;S)}{N} \tag{4.11}$$

$$Kazanç(A,T;S) = Ent(S) - E(A,T;S) \tag{4.12}$$

$$\begin{aligned}\Delta(A,T;S) = {} & \log_2(3^Z - 2) - \\ & [Z.Ent(S) - Z_1.Ent(S_1) - Z_2.Ent(S_2)]\end{aligned} \tag{4.13}$$

Burada N S kümesi içerisindeki örnek sayısını Z_1 ve Z_2 ise sırasıyla S_1 ve S_2 içerisindeki sınıf sayılarını belirtmektedir.

4.4. Temel Bileşen Analizi (TBA)

TBA, veri kümesi içerisindeki örüntülerin tanımlanmasını sağlayan ve benzerliklerini ve farklarını vurgulayarak veriyi daha uygun bir biçimde ifade etmek amacıyla kullanılan bir yöntemdir. Bir başka deyişle TBA, veri kümesinin daha hızlı

ve daha verimli bir biçimde işlenmesi amacıyla çeşitliliğini mümkün olduğunca kaybetmeden boyutunun indirgenmesi amacıyla kullanılan istatistiksel bir metottur (Jolliffe 1986; Smith 2002).

Çok boyutlu veri kümesinin istatistiksel analizindeki temel amaç boyutlar arasında bir ilişki olup olmadığının araştırılmasıdır. TBA, yüksek boyutlu verilerde gözlemlenemeyen örüntülerin elde edilmesini amaçlayan bir yöntemdir. Bu amaçla TBA'nde veri kümesinin yeniden modellenmesi *kovaryans matrisi*, *eigen değerler* ve *eigen vektörler* yardımıyla gerçekleştirilmektedir (Smith 2002).

Tek boyutlu veri kümesinde verinin dağılımı incelenmek istendiğinde *standart sapma* ve *varyans* gibi istatistiksel değerler kullanılabilmektedir. Ancak veri kümesinin çok boyutlu olduğu durumlarda bu iki metot yeterli olmamaktadır. Bir başka deyişle standart sapma ve varyans ile veri kümesinin her bir boyutu diğer boyutlardan bağımsız olarak hesaplanmaktadır.

Kovaryans, veri kümesinin boyutlarının birbiri ile ilgili olacak şekilde ortalamadan ne kadar farklı olduğunun göstergesi olan bir değerdir. Bu değer her zaman iki boyut arasında hesaplanır. Belirtilen x ve y gibi iki boyut için kovaryans eşitlik 4.14'te verildiği gibi hesaplanır.

$$kov(x,y)=\frac{\sum_{i=1}^{n}(x_i-x')(y_i-y')}{n-1} \tag{4.14}$$

Bu ifadede x_i birinci boyuttaki elemanları, x' birinci boyuta ait ortalamayı, y_i ikinci boyuttaki elemanları, y' ikinci boyuta ait ortalamayı ve n ise boyutun uzunluğunu belirtmektedir. Pozitif değerli bir kovaryans birinci boyutla ikinci boyutun doğru orantılı olarak değiştiğini, negatif değerli bir kovaryans ise iki boyutun ters orantılı olarak değiştiğini ifade etmektedir. Kovaryans değerinin 0 olması ise iki boyut birbirinden bağımsız olarak değişmekte olduğunu ifade etmektedir.

İki'den daha fazla sayıda boyuta sahip olan bir veri kümesi için birden daha faza kovaryans değeri hesaplanacaktır. Buna göre *mxn* boyutundaki bir veri kümesi için hesaplanan kovaryans değerlerinin oluşturduğu matrise *kovaryans matrisi* adı verilir. Eşitlik 4.15'te *mxn* boyutundaki bir veri kümesinden elde edilen *n* boyutlu bir kovaryans matrisi verilmektedir (Smith 2002).

$$\overline{\overline{C}} = (c_{i,j}, c_{i,j} = kov(\overline{B}_i, \overline{B}_j)) \tag{4.15}$$

Burada $\overline{\overline{C}}$, n satıra ve n sütuna sahip kovaryans matrisini, $\overline{B}_i$ ve $\overline{B}_j$ ise sırasıyla *i.* ve *j.* boyutları belirtmektedir. Bir başka ifade ile *mxn* boyutlu bir veri kümesinin kovaryans matrisi *nxn* boyutlarında ve kare bir matris olacaktır. Buna göre $\bar{x}$, $\bar{y}$ ve $\bar{z}$ gibi üç boyuta sahip bir veri kümesi için oluşacak olan örnek kovaryans matrisi eşitlik 4.16'teki gibi olacaktır.

$$\overline{\overline{C}} = \begin{pmatrix} kov(\bar{x},\bar{x}) & kov(\bar{x},\bar{y}) & kov(\bar{x},\bar{z}) \\ kov(\bar{y},\bar{x}) & kov(\bar{y},\bar{y}) & kov(\bar{y},\bar{z}) \\ kov(\bar{z},\bar{x}) & kov(\bar{z},\bar{y}) & kov(\bar{z},\bar{z}) \end{pmatrix} \tag{4.16}$$

Eşitlik 4.16'e bakıldığında $kov(\bar{x},\bar{y})$ ile $kov(\bar{y},\bar{x})$ biririne eşit olacağından kovaryans matrisi diyagonale göre simetrik olacaktır. Aynı zamanda $kov(\bar{x},\bar{x})$ ise $\bar{x}$ boyutunun varyansı olacaktır.

TBA'nde kovaryans matrisinin oluşturulmasından sonra eigen vektörlerin ve eigen değerlerin hesaplanarak yeni veri kümesinin eigen vektörlerin birleştirilmesi ile oluşturulması sağlanmaktadır. Buna göre bir eigen vektör ve eigen değer, veri kümesine ait elde edilen kovaryans matrisini kullanarak eşitlik 4.17'deki şartı sağlanması şeklinde elde edilir (Smith 2002).

$$(\overline{\overline{C}} - \lambda)\overline{V} = 0 \tag{4.17}$$

Burada $\overline{\overline{C}}$ kovaryans matrisini, $\overline{V}$ eigen vektörü ve λ ise eigen değeri göstermektedir.

n boyutlu bir veri kümesi için n adet eigen vektör ve n adet de eigen değer oluşacaktır. Kovaryans matrisinden elde edilen eigen vektörler kendilerine karşılık gelen eigen değerlere göre büyükten küçüğe doğru sıralandığında en büyük eigen değere karşılık gelen eigen vektör veriyi en anlamlı olarak ifade eden vektördür. Bu eigen vektör aynı zamanda *temel bileşen* olarak da adlandırılır.

5. KAH'NIN TEŞHİSİ KONUSUNDA GERÇEKLEŞTİRİLEN UYGULAMALAR

Tez çalışmasında gerçekleştirilen tüm uygulamalar MATLAB 7.0 platformunda gerçekleştirilmiştir. YSA uygulamaları için MATLAB'ın YSA araçları, DVM uygulamaları için LIBSVM (Chang ve Lin 2001) paketi kullanılmış olup YBTS, GA, PSO, İPSO, K-NN, TBA ve ayrıklaştırma algoritmaları MATLAB uygulama geliştirme ortamında ayrı ayrı kodlanmıştır.

5.1. Karşılaştırma ve Doğrulama

5.1.1. Tanısal testler

Standart kriter testler bir hastalığın varlığı ya da yokluğuna kesin bir tanı koyan test olarak kabul edilir. Damar tıkanıklığı konusunda KAG gerçekleştirilmesi bu testlere örnek olarak verilebilir. Ancak standart kriter testler çoğunlukla dezavantajlarla uygulanırlar; genel olarak pahalı, yaygın olmayan, daha invazif ve risklidirler. Bu dezavantajlar hekimleri, standart kriter testlerin vekilleri olarak tarama ve tanısal testleri kullanmaya mecbur kılmaktadır (Elavunkal ve Sinert 2007; Nielsen ve Lang 1999).

Genel olarak tıp alanında kullanılan tanısal testler hastaların hastalık olasılığına karşın hekimlere yardımcı olmak amacıyla uygulanırlar. Tanısal testlerin klinik çalışmaları, testin standart kriterine dayalı doğruluğunu değerlendirir. Başka bir ifade ile tanısal testlerde, tarama testlerinin sonuçları kesin olan standart kriterler ile karşılaştırılır. Standart kriter testlerin sadece tanısal doğruluğu vermesine karşın bu testler hekimlere hastalığın teşhisini daha anlamlı yapan değerler sunmaktadır. Bu değerler *duyarlılık*, *özgüllük*, *pozitif tahmin ettirici*, *negatif tahmin ettirici* ve *tanısal*

doğruluk değerleridir ve Tablo 5.1'de verilen *hata matrisi* (confusion matrix) kullanılarak elde edilir (Elavunkal ve Sinert 2007; Nielsen ve Lang 1999).

Tablo 5.1 Hata Matrisi

		Gerçek	
		Pozitif	Negatif
Test	Pozitif	Gerçek Pozitif	Yalancı Pozitif
	Negatif	Yalancı Negatif	Gerçek Negatif

Hata matrisi yapay zeka ve makine öğrenmesi tekniklerinde danışmanlı öğrenme için sınıflandırma ve tahmin sonuçlarının gözlemlenmesine ve eleştirilmesine yarayan bir matristir. *Gerçek pozitif*, *yalancı pozitif*, *yalancı negatif* ve *gerçek negatif* ifadeleri aşağıdaki gibi tanımlanabilir;

- Gerçek pozitif (GP) : Gerçekte pozitif olan örneklerin testte de pozitif sonuç vermesidir.
- Yalancı pozitif (YP) : Gerçekte negatif olan örneklerin testte pozitif sonuç vermesidir.
- Yalancı negatif (YL) : Gerçekte pozitif olan örneklerin testte negatif sonuç vermesidir.
- Gerçek negatif (GN) : Gerçekte negatif olan örneklerin testte de negatif sonuç vermesidir.

Hata matrisinden elde edilen GP, YP, YL ve GN değerlerine göre duyarlılık, özgüllük, pozitif tahmin ettirici, negatif tahmin ettirici ve tanısal doğruluk değerleri hesaplanır.

Duyarlılık (Duy): Hasta olan örneklerin teste pozitif sonuç verme olasılığıdır. Eşitlik 5.1'e göre hesaplanır.

$$Duy = \frac{GP}{GP + YN} \tag{5.1}$$

Özgüllük (Özg): Hasta olmayan örneklerin teste negatif sonuç verme olasılığıdır. Eşitlik 5.2'ye göre hesaplanır.

$$Özg = \frac{GN}{GN + YP} \tag{5.2}$$

Pozitif tahmin ettirici değer (Ptd): Teste pozitif sonuç veren örneklerin hasta olma olasılığıdır. Eşitlik 5.3'e göre hesaplanır.

$$Ptd = \frac{GP}{GP + YP} \tag{5.3}$$

Negatif tahmin ettirici değer (Ntd): Teste negatif sonuç veren örneklerin hasta olmama olasılığıdır. Eşitlik 5.4'e göre hesaplanır.

$$Ntd = \frac{GN}{GN + YN} \tag{5.4}$$

Tanısal doğruluk (Td): Testin hasta örnekleri hasta olarak sağlıklı örnekleri de sağlıklı olarak teşhis edebilme olasılığıdır. Eşitlik 5.5'e göre hesaplanır.

$$Td = \frac{GP + GN}{GP + YP + GN + YN} \tag{5.5}$$

5.1.2. Cohen'in Kappa katsayısı

Cohen'in Kappa katsayısı (κ) değerlendiriciler arası güvenilirlik ölçütü olarak tanımlanır. İstatistiksel bir değer olan bu katsayı aynı veriyi değerlendiren iki değerlendiricinin sonuçları arasındaki uyumu ölçer. Kappa katsayısı [0,1] aralığında değer alır ve 1 değerine sahip bir Kappa katsayısı değerlendiricilerin mükemmel bir

uyuma sahip olduğunu belirtirken 0 değerine sahip bir Kappa katsayısı değerlendiriciler arasındaki uyumun şanstan başka bir şekilde olamayacak kadar rastgele olduğunu belirtir. Cohen'in Kappa ölçütü uyumun şansa bağlı olarak oluşabileceğini ele alması nedeniyle basit yüzde uyumlarından daha gerçekçi sonuçlar sunmaktadır (Agresti 2007; Sprent ve Smeeton 1999).

Cohen'in Kappa katsayısını hesaplamak için Tablo 5.1'deki hata matrisine benzer değerlendiricilerin durumlara verdikleri değerlerin karşılaştırılmasını gösteren bir *olasılık tablosu* kullanılmaktadır. Burada, tıp alanındaki hastalık tahminlerinde 2 değerlendirici için (gerçek ve test işlemi iki farklı değerlendirici olarak kabul edildiğinde) olasılık tablosu ile hata matrisinin birbirine eşit olduğu söylenebilir. Daha sonra Kappa katsayısı bu olasılık tablosuna göre eşitlik 5.6'ya kullanılarak hesaplanır.

$$\kappa = \frac{G - B}{D - B} \tag{5.6}$$

Burada G (*gerçek*) değerlendiricilerin kaç defa aynı değerlendirmeyi yaptığını, B (*beklenen*) değerlendiricilerin kaç defa şans eseri aynı değerlendirmeyi yaptığının oranını, D (*deneme*) gerçekleştirilen toplam deneme sayısını belirtir.

Cohen'in Kappa katsayısı evrensel olarak kabul edilmemesine karşın uygulamalarda sıklıkla Landis ve Koch'un (1977) uyum değerlerini kullanarak değerlendirilmektedirler. Buna göre değerlendiriciler arasındaki uyum ele alındığında, $\kappa<0$ hiç uyum olmadığını, $0\leq\kappa\leq0.20$ çok düşük bir uyumun olduğunu, $0.21\leq\kappa\leq0.40$ düşük bir uyum olduğunu, $0.41\leq\kappa\leq0.60$ orta derecede bir uyum olduğunu, $0.61\leq\kappa\leq0.80$ yüksek bir uyum olduğunu ve $0.81\leq\kappa\leq1.00$ hemen hemen mükemmel bir uyum olduğunu göstermektedir. Bununla birlikte 0.70'den daha büyük bir Kappa katsayısı için değerlendiriciler arasındaki uyumun yeterli olduğu da söylenebilir.

5.1.3. Çapraz doğrulama

Çapraz doğrulama metodu özellikle tahmin ve sınıflandırma algoritmalarında geliştirilen modelin daha anlamlı ve güvenli olmasını sağlamak ve geliştirilen modeli genelleştirmek amacıyla kullanılan bir yöntemdir. Bu yöntemin temel amacı veri kümesinden *eğitme* ve *test* amacıyla kullanılacak olan birbirini tamamlayan rastgele iki alt küme oluşturmak ve veri kümesini değerlendiren modelin eğitme aşamasında eğitme için oluşturulan alt kümenin, test aşamasında ise test için oluşturulan alt kümenin kullanılmasını sağlayarak veri içerisindeki katı değerlendirmeyi genelleştirmeye çalışmaktır. Birden fazla sayıdaki çapraz doğrulama ile gerçekleştirilen ikiye parçalama genelleştirmeyi daha da artıracaktır (An ve ark. 2007; Shao 1993). Yaygın olarak kullanılan üç çapraz doğrulama yöntemi mevcuttur. Bunlar *k-Fold*, *holdout* ve *leave-one-out* çapraz doğrulama yöntemleridir.

Holdout Çapraz Doğrulama:

En sık kullanılan çapraz doğrulama yöntemidir. Bu yöntemde veri kümesi belirlenen bir oranda eğitme ve test amacıyla kullanılacak olan birbirini tamamlayan ve rastgele iki alt kümeye ayrılır. İki alt kümeden biri veri kümesini değerlendiren modelin eğitme aşamasında diğeri ise test aşamasında kullanılır. Uygulanması basit olduğu için çok tercih edilen bu yöntemin kullanılması modelin çok çeşitli sonuçlar vermesine neden olabilir. Bu yüzden bu metotta alt kümelerin oluşturulmasındaki oran ve alt kümelerin elde edileceği veri kesme noktaları oldukça önemlidir (Shao 1993; Fukunaga 1990).

k-Fold Çapraz Doğrulama:

Holdout yönteminin geliştirilmesini sağlayan bu yöntemde veri kümesi rastgele seçilen ve birbirini tamamlayan k adet alt kümeye ayrılır. Her bir aşamada oluşturulan alt kümelerden sırasıyla biri test kümesi olarak, geri kalan k-1 adet alt küme ise eğitme alt kümesi olarak kabul edilerek veri kümesi değerlendirici model ile değerlendirilir. Eğitme ve test işlemlerinde elde edilen k adet sonucun ve hatanın ortalaması modelin genelleştirilmiş sonucu ve hatasını gösterir. Bu yöntem eğitme ve test alt kümeleri oluşturmak amacıyla k defa tekrar ettiği için hesaplama maliyetini

artırmaktadır. Ancak bu tekrar sonucunda holdout yönteminin sonuçlarında oluşacak olan çeşitliliği de azaltmaktadır. Bu yöntemin bir diğer çeşidi ise veri kümesinin rastgele eğitim ve test için kullanılacak iki alt kümeye ayrılması ve bunun *k* defa tekrar edilmesi şeklinde gerçekleştirilmektedir (Shao 1993; Fukanaga 1990).

Leave-one-out Çapraz Doğrulama:

Bu yöntem hesaplama maliyeti yönünden en ağır çapraz doğrulama yöntemidir. *k*-fold çapraz doğrulama yönteminin tutarlı en uç şekli olarak düşünülebilecek olan bu yöntem *k*'nın veri kümesindeki örnek sayısına eşit olarak alınması şeklinde de tanımlanabilir. Yöntemde, veri kümesi içerisindeki *n* örnekten biri test kümesi olarak kabul edilir. Geriye kalan *n*-1 örnek eğitim kümesi olarak kabul edilir. Dolayısıyla yöntem *n* defa tekrar edildikten sonra genelleştirilmiş sonuçlar ve hatalar ortalama alınarak elde edilir (Shao 1993; Fukanga 1990).

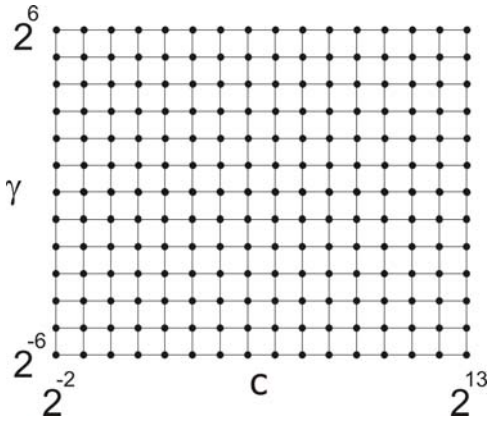
5.2. KAH'nın DVM ile Teşhisi

Tez çalışmasında KAH'nın teşhisinde gerçekleştirilen uygulamalardan biri Bölüm 2.3'de bireylere ait EST'nden elde edilen veri kümesinin DVM kullanılarak sınıflandırılmasıdır (Babaoğlu ve ark. 2010a). Buna göre 480 bireye ait 23 özelliğin bulunduğu veri kümesi giriş olarak, KAH'nın varlığını belirten özellikte çıkış olarak kabul edilmiştir. EST veri kümesinin DVM ile sınıflandırılması için 480 bireye ait 23 özellik [-1,1] aralığına normalleştirilmiştir.

DVM ile gerçekleştirilen sınıflandırma işlemlerinin büyük bir çoğunluğunda parametre sayısının az olması ve dolayısıyla parametre optimizasyonu için ihtiyaç duyulan işlem maliyetinin az olması nedeniyle RBF çekirdeğin kullanıldığı gözlemlenmiştir. Bu tez çalışmasında, EST veri kümesinin DVM ile sınıflandırılması için RBF çekirdek tercih edilmiştir.

EST veri kümesinin [-1,1] aralığına normalleştirilmesinin ardından grid-search yöntemi ile (Cormen ve ark. 2001) DVM'nin RBF çekirdeğine ait en uygun parametrelerin belirlenmesi sağlanmıştır. Burada, RBF çekirdeğine ait c ve γ

parametreleri sırasıyla 2^n ve 2^m şeklinde kullanılmış ve parametre optimizasyon gridi $-2 \le n \le 13$ ve $-6 \le m \le 6$ olacak şekilde tasarlanmıştır (bkz. Şekil 5.1). Buna göre çekirdek parametreleri $-0.25 \le c \le 8192$ ve $-0{,}015625 \le \gamma \le 64$ şeklinde olacaktır.



Şekil 5.1 DVM için RBF çekirdek parametreleri optimizasyon grid'i

Uygulamada %5'den daha büyük eğitme hatasına sahip parametre çiftleri optimum model için uygunsuz olarak kabul edilmiştir. Aynı zamanda EST veri kümesinin DVM yöntemi ile sınıflandırılmasında 5-fold çapraz doğrulama yöntemi kullanılmıştır. Elde edilen en uygun DVM modelinde RBF çekirdeğe ait c ve γ parametreleri sırasıyla 8 ve 1'dir. Optimum RBF çekirdek parametreleri kullanıldığında DVM'nin EST verilerini kullanarak KAH teşhisindeki eğitme hatası %0,31 ve test başarısı da %76,67 olarak elde edilmiştir.

5.3. KAH'nın DVM ile Teşhisinde GA ve İPSO Kullanarak Özellik Seçimi

Tez çalışmasında EST verilerine bağlı olarak KAH teşhisinde gerçekleştirilen bir diğer uygulamada Bölüm 5.2'teki sınıflandırma sonuçlarının başarısını artırmak amacıyla veri kümesi üzerinde GA ve İPSO kullanarak özellik seçimi yapılmıştır

(Babaoğlu ve ark. 2010a). Her iki yöntemde de amaçlanan EST veri kümesinin 23 özelliğinin hangilerinin KAH teşhisi konusundaki sınıflandırma başarısını artırdığının gözlenmesi ve dolayısıyla teşhis başarısının artırılmasıdır.

Buna göre 480 bireye ait 23 özelliğin bulunduğu EST veri kümesi [-1,1] arasına normalleştirilmiştir. Sınıflandırma işlemi GA ve İPSO yöntemlerinin sırasıyla her bir bireyi ya da her bir parçacığı için DVM kullanılarak gerçekleştirilmiştir.

GA ile özellik seçiminin gerçekleştirildiği uygulamada 23 adet gene sahip kromozomlar kullanılmıştır. Burada her bir genin ikili değeri, EST veri kümesi içerisinde kendisine karşılık gelen özelliğin sınıflandırmaya dahil edilip edilmeyeceğini göstermektedir. Kromozoma ait bir genin 0 değeri kendisine karşılık gelen özelliğin seçilmeyeceğini, 1 değeri ise kendisine karşılık gelen özelliğin seçileceğini belirtmektedir. DVM kullanılarak gerçekleştirilen sınıflandırma işleminde her bir kromozoma ait genlerin ikili durumlarına göre oluşturulan 1 ile 23 arasında özelliğe sahip indirgenmiş veri kümesi DVM kullanılarak sınıflandırılmakta ve sınıflandırma başarısı ile eğitme hatası arasındaki fark da kromozoma ait uygunluk değeri olarak kullanılmaktadır. GA'nın seleksiyon aşamasında kromozomların seçimi rulet tekeri tekniğine göre gerçekleştirilmiştir. Yöntemde klasik GA'dan farklı olarak algoritmaya bir kontrol aşaması eklenmiştir. Bu kontrol aşamasında çaprazlama ve mutasyon işlemleri sonucunda herhangi bir kromozoma ait tüm genlerin 0 olması durumunda rastgele bir genin 1 olması sağlanmıştır. Bu kontrol aşamasına göre hiçbir özelliğin seçilmediği bir durum oluşursa sınıflandırma gerçekleştirilemeyeceği için en azından 1 özelliğin kullanılması sağlanmıştır.

GA ile özellik seçim yönteminde RBF çekirdeğe sahip DVM'ler kullanılmıştır. RBF çekirdeğine ait c ve γ parametreleri sırasıyla 2^n ve 2^m şeklinde kullanılmış ve parametre optimizasyon gridi $-2 \le n \le 13$ ve $-6 \le m \le 6$ olacak şekilde tasarlanmıştır (bkz. Şekil 5.1). Buna göre farklı parametrelerin kullanıldığı her bir RBF çekirdek modeli için GA ile özellik seçim işlemi tekrarlanmış, en uygun özellik vektörü (en uygun kromozom) RBF parametrelerine de bağlı olarak seçilmiştir. Yöntemde ayrıca indirgenmiş veri kümeleri 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır.

GA ile özellik seçim modelinde popülasyonu 10 adet kromozom oluşturmaktadır ve yöntem 200 iterasyon boyunca gerçekleştirilmiştir. Mutasyon ve çaprazlama oranı sırasıyla 0.05 ve 0.25 olarak kullanılmıştır.

İPSO ile özellik seçiminin gerçekleştirildiği uygulamada ise 23 adet ikili hücreye sahip parçacıklar kullanılmıştır. Burada her bir hücrenin ikili değeri, GA ile özellik seçim tekniğindeki kromozomlara ait genlere eşdeğer bir şekilde, EST veri kümesi içerisinde kendisine karşılık gelen özelliğin sınıflandırmaya dahil edilip edilmeyeceğini göstermektedir. Parçacığa ait bir hücrenin 0 değeri kendisine karşılık gelen özelliğin seçilmeyeceğini, 1 değeri ise kendisine karşılık gelen özelliğin seçileceğini belirtmektedir. GA ile özellik seçim tekniğine eşdeğer olarak bu yöntemde de, DVM kullanılarak gerçekleştirilen sınıflandırma işleminde her bir parçacığa ait hücrelerin ikili durumlarına göre oluşturulan 1 ile 23 arasında özelliğe sahip indirgenmiş veri kümesi DVM kullanılarak sınıflandırılmakta ve sınıflandırma başarısı ile eğitme hatası arasındaki fark da parçacığa ait uygunluk değeri olarak kullanılmaktadır. Bu yöntemde de GA ile özellik seçim yöntemindeki kontrol aşamasının aynı nedenle kullanılması sağlanmıştır. Kontrol aşamasında hücrelerin hızına bağlı olarak güncellenmesinin ardından herhangi bir parçacığa ait tüm hücrelerin 0 olması durumunda rastgele bir hücrenin 1 olması sağlanmıştır.

İPSO ile özellik seçim yönteminde RBF çekirdeğe sahip DVM'ler kullanılmıştır. RBF çekirdeğine ait c ve γ parametreleri sırasıyla 2^n ve 2^m şeklinde kullanılmış ve parametre optimizasyon gridi $-2 \le n \le 13$ ve $-6 \le m \le 6$ olacak şekilde tasarlanmıştır (bkz. Şekil 5.1). Buna göre farklı parametrelerin kullanıldığı her bir RBF çekirdek modeli için İPSO ile özellik seçim işlemi tekrarlanmış, en uygun özellik vektörü (en uygun parçacık) RBF parametrelerine de bağlı olarak seçilmiştir. Yöntemde ayrıca indirgenmiş veri kümeleri 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır.

İPSO ile özellik seçim modelinde sürüyü 10 adet parçacık oluşturmaktadır ve yöntem 200 iterasyon boyunca gerçekleştirilmiştir. Parçacığa ait hız sınırlandırıcı paremetreler $v_{\min}$ ve v_{mak} ise sırasıyla -6 ve 6 olarak, atalet ağırlığı ise eşitlik 4.4'e göre kullanılmıştır.

KAH teşhisi konusunda gerçekleştirilen bu uygulamalarda, İPSO ve GA özellik seçim yöntemleri ile indirgenen EST veri kümesinin DVM kullanılarak elde edilen en uygun RBF çekirdek parametreleri, eğitim hataları ve sınıflandırma başarıları tüm özelliklerin indirgenmeden kullanıldığı DVM modelindeki (Bölüm 5.2) sonuçlarla karşılaştırmalı olarak Tablo 5.2'de verilmiştir.

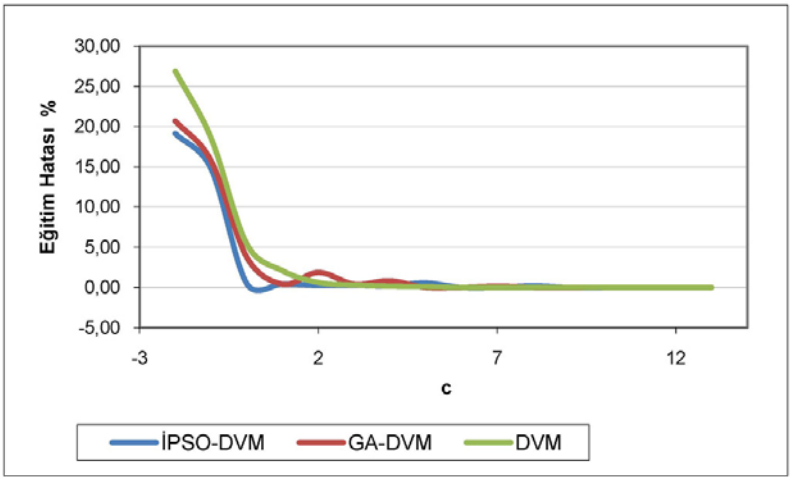
Tablo 5.2 İPSO-DVM, GA-DVM ve DVM yöntemlerine ait en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları

Yöntem	c	γ	**Eğitim Hatası (%)**	**Sınıflandırma Başarısı (%)**	**Özellik Sayısı**
İPSO-DVM	4	8	0,26	81,46	11
GA-DVM	512	4	0,00	79,17	12
DVM	8	1	0,31	76,67	23

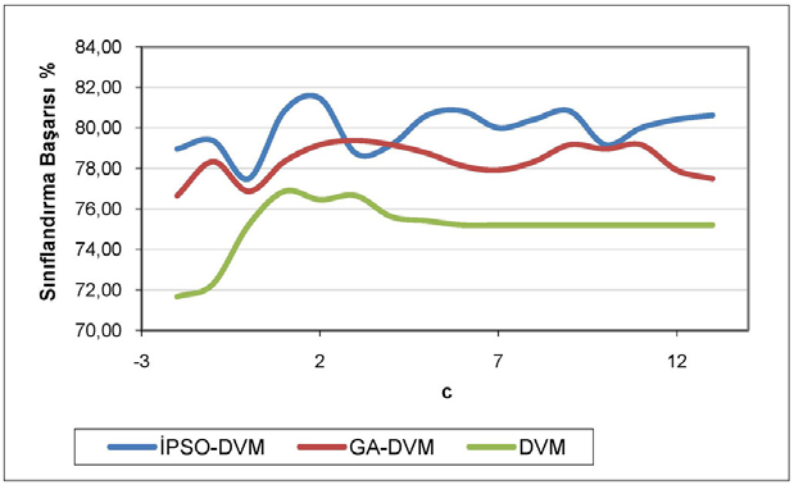
KAH teşhisi konusunda GA ile özellik seçimine ve İPSO ile özellik seçimine ait indirgenmiş EST veri kümesi kullanılarak gerçekleştirilen DVM sınıflandırma sonuçları ve eğitim hataları RBF çekirdeğe ait $c = 2^n$ ve $\gamma = 2^m$ şeklinde kullanılan parametrelerin değişimine bağlı olarak Şekil 5.2, Şekil 5.3, Şekil 5.4 ve Şekil 5.5'de verilmiştir. Belirtilen grafiklerde İPSO ve GA ile indirgenmiş EST veri kümesine ait sonuçların ve eğitim hatalarının yanı sıra tüm özelliklerin indirgenmeden kullanıldığı salt DVM sınıflandırma sonuçları da karşılaştırma amaçlı olarak verilmiştir. Şekil 5.2 ve Şekil 5.3'te İPSO ve GA ile özellik seçimi ile gerçekleştirilen DVM sınıflandırma yöntemiyle birlikte salt DVM sınıflandırma yönteminde (Bölüm 5.2) RBF çekirdeğe ait optimum γ parametreleri sabit ve İPSO-DVM, GA-DVM ve DVM modelleri için sırasıyla 8, 4 ve 1'e eşit olarak alınmış ve c parametresinin değişiminin sırasıyla eğitme hatası ve test başarısı üzerindeki etkileri gösterilmektedir. Şekil 5.4 ve Şekil 5.5'de İPSO ve GA ile özellik seçimi ile gerçekleştirilen DVM sınıflandırma yöntemiyle birlikte salt DVM sınıflandırma yönteminde (Bölüm 5.2) RBF çekirdeğe ait optimum c parametreleri sabit ve İPSO-DVM, GA-DVM ve DVM modelleri için

sırasıyla 4, 512 ve 8'e eşit olarak alınmış ve γ parametresinin değişiminin sırasıyla eğitme hatası ve test başarısı üzerindeki etkileri gösterilmektedir.

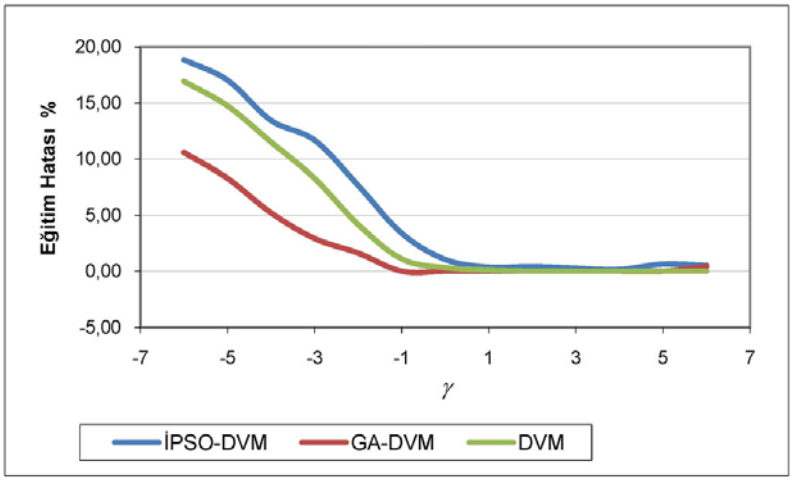
Şekil 5.2, Şekil 5.3, Şekil 5.4 ve Şekil 5.5 incelendiğinde RBF çekirdek parametrelerinin değişim sürecinde İPSO-DVM modelinin eğitim hatasının GA-DVM ve DVM modellerinden genellikle daha düşük değerlerde olduğu, aynı zamanda test başarısının ise genellikle her iki modelden de daha yüksek değerlerde olduğu gözlemlenmektedir. Buna göre, KAH teşhisi konusunda EST verilerinin değerlendirilmesinde İPSO-DVM modelinin diğer iki modelden de daha uygun bir model olduğu gözlemlenmektedir.



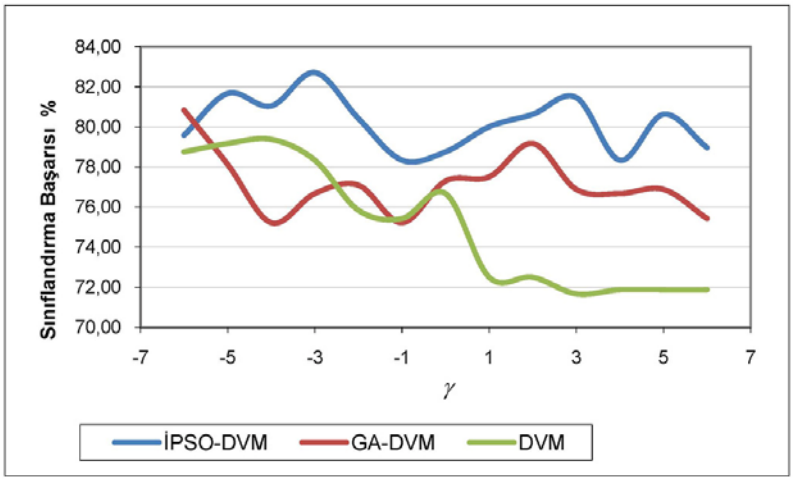
Şekil 5.2 Sabit γ parametresi için (İPSO-DVM'de $\gamma = 8$; GA-DVM'de $\gamma = 4$; DVM'de $\gamma = 1$) c parametresinin değişimine bağlı eğitim hatasının değişimi



Şekil 5.3 Sabit γ parametresi için (İPSO-DVM'de $\gamma = 8$; GA-DVM'de $\gamma = 4$; DVM'de $\gamma = 1$) c parametresinin değişimine bağlı sınıflandırma başarısının değişimi



Şekil 5.4 Sabit c parametresi için (İPSO-DVM'de $c = 4$; GA-DVM'de $c = 512$; DVM'de $c = 8$) γ parametresinin değişimine bağlı eğitim hatasının değişimi



Şekil 5.5 Sabit c parametresi için (İPSO-DVM'de $c = 4$; GA-DVM'de $c = 512$; DVM'de $c = 8$) γ parametresinin değişimine bağlı sınıflandırma başarısının değişimi

5.4. KAH'nın DVM ile Teşhisinde TBA Kullanılarak Özellik İndirgenmesi

Tez çalışmasında EST verilerine bağlı olarak KAH teşhisinde gerçekleştirilen ve DVM sınıflandırıcısının kullanıldığı bir diğer uygulamada, veri kümesindeki özelliklerin TBA yöntemi ile indirgenmesinin sınıflandırma başarısı üzerindeki etkisi araştırılmıştır (Babaoğlu ve ark. 2010b).

Uygulama, Bölüm 5.2'teki uygulamayı temel alarak gerçekleştirilmiştir. Buna göre 480 bireye ait 23 özelliğin bulunduğu EST veri kümesi [-1,1] arasına normalleştirilmiştir. Toplam özellik sayısı 23 olduğundan dolayı normalleştirilmiş veri kümesi TBA yöntemi ile [2,22] aralığındaki özellik sayılarına bağlı olarak indirgenmiştir ve toplam 21 adet indirgenmiş veri kümesi (TBA2, TBA3, …, TBA22) elde edilmiştir.

İndirgenmiş her bir veri kümesinin sınıflandırılması için RBF çekirdeğe sahip DVM'ler kullanılmıştır. RBF çekirdeğine ait c ve γ parametreleri sırasıyla 2^n ve 2^m şeklinde kullanılmış ve parametre optimizasyon gridi $-2 \le n \le 13$ ve

$-6 \le m \le 6$ olacak şekilde tasarlanmıştır (bkz. Şekil 5.1). Buna göre her bir indirgenmiş veri kümesi için RBF çekirdeğe ait parametre optimizasyon işlemi tekrarlanmıştır. Yöntemde ayrıca indirgenmiş veri kümeleri 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır ve %5'den daha büyük eğitme hatasına sahip parametre çiftleri optimum model için uygunsuz olarak kabul edilmiştir.

KAH teşhisi konusunda gerçekleştirilen bu uygulamada, TBA yöntemi ile indirgenen EST veri kümesinin DVM kullanılarak sınıflandırılmasında elde edilen en uygun RBF çekirdek parametreleri, eğitim hataları ve sınıflandırma başarıları Tablo 5.3'de verilmiştir.

Tablo 5.3 TBA ile indirgenmiş veri kümelerinin DVM yöntemi ile sınıflandırılmasında elde edilen en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları

Model Adı	c	γ	**Eğitim Hatası (%)**	**Sınıflandırma Başarısı (%)**	**Özellik Sayısı**
TBA-2	8	64	0,05	72,92	2
TBA-3	1	64	0,16	71,88	3
TBA-4	1024	8	0,00	73,13	4
TBA-5	256	1	0,00	73,96	5
TBA-6	2	1	0,16	76,04	6
TBA-7	2	0,5	0,78	76,46	7
TBA-8	2	0,5	0,63	76,46	8
TBA-9	16	0,25	0,16	76,46	9
TBA-10	64	0,25	0,00	77,50	10
TBA-11	8192	0,25	0,00	77,92	11
TBA-12	4	0,25	0,42	77,92	12
TBA-13	1024	0,25	0,00	77,50	13
TBA-14	256	0,125	0,00	77,50	14
TBA-15	2	0,25	0,89	78,54	15
TBA-16	64	0,125	0,10	78,33	16
TBA-17	128	0,125	0,00	77,92	17
TBA-18	**64**	**0,125**	**0,05**	**79,17**	**18**
TBA-19	64	0,125	0,05	78,33	19
TBA-20	16	0,125	0,26	77,71	20
TBA-21	16	0,125	0,21	77,92	21
TBA-22	32	0,125	0,05	77,92	22

TBA ile indirgenmiş veri kümelerinin sınıflandırma sonuçlarına bakıldığında, veri kümesinin 18 özelliğe indirgendiği veri kümesi ile gerçekleştirilen modelin en

yüksek sınıflandırma başarısına sahip olduğu gözükmektedir. TBA yöntemi ile 18 özelliğe indirgenen veri kümesindeki en uygun DVM modeline ait RBF çekirdek parametreleri, eğitim hatası ve sınıflandırma başarısı tüm özelliklerin indirgenmeden kullanıldığı DVM modelindeki (Bölüm 5.2) sonuçlarla karşılaştırmalı olarak Tablo 5.4'te verilmiştir.

Tablo 5.4 TBA-18-DVM ve DVM yöntemlerine ait en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları

Yöntem	c	γ	Eğitim Hatası (%)	Sınıflandırma Başarısı (%)	Özellik Sayısı
TBA-18-DVM	64	0,125	0,05	79,17	18
DVM	8	1	0,31	76,67	23

5.5. KAH'nın DVM ile Teşhisinde Ayrıklaştırma Kullanarak Özellik İndirgenmesi

Tez çalışmasında EST verilerine bağlı olarak KAH teşhisinde gerçekleştirilen ve DVM sınıflandırıcısının kullanıldığı bir diğer uygulamada, veri kümesinin ayrıklaştırma yöntemi ile işlenmesinin sınıflandırma başarısı üzerindeki etkisi araştırılmıştır (Babaoğlu ve ark. 2009a).

Uygulamada EST veri kümesine eşit aralığa ve eşit frekansa dayalı ve entropi tabanlı ayrıklaştırma yöntemleri uygulanarak ön işlemeye tabi tutulmuştur. Ön işleme sonrasında oluşan 480 bireye ait üç farklı işlenmiş EST veri kümesi [-1,1] arasına normalleştirilmiştir.

Belirtilen üç farklı ayrıklaştırma yöntemi ile ön işlemeye tutulmuş üç veri kümesinin her birinin sınıflandırılması için RBF çekirdeğe sahip DVM'ler kullanılmıştır. RBF çekirdeğine ait c ve γ parametreleri sırasıyla 2^n ve 2^m şeklinde kullanılmış ve parametre optimizasyon gridi $-2 \le n \le 13$ ve $-6 \le m \le 6$ olacak

şekilde tasarlanmıştır (bkz. Şekil 5.1). Buna göre her bir ayrıkaştırma yöntemi ile ön işleme gerçekleştirilmiş veri kümesi için RBF çekirdeğe ait parametre optimizasyon işlemi tekrarlanmıştır. Optimum sınıflandırma modelini seçmek amacıyla, eşit aralığa ve eşit frekansa dayalı ayrıklaştırma yöntemlerinin her birinde *k* parametresi [2,5] aralığındaki tüm değerler için tekrar edilmiştir. Yöntemde ayrıca indirgenmiş veri kümeleri 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır ve %5'den daha büyük eğitme hatasına sahip parametre çiftleri optimum model için uygunsuz olarak kabul edilmiştir.

KAH teşhisi konusunda gerçekleştirilen bu uygulamada, eşit aralığa dayalı ayrıklaştırma yöntemine ait işlenmiş veri kümesini kullanarak elde edilen en optimum sınıflandırma modellerinde aralık boyutunu belirleyen *k* parametresi 3 olarak bulunmuştur. Benzer şekilde, eşit frekansa dayalı ayrıklaştırma yöntemine ait işlenmiş veri kümesini kullanarak elde edilen en optimum sınıflandırma modellerinde frekans boyutunu belirleyen *k* parametresi 2 olarak bulunmuştur. Entropi tabanlı ayrıklaştırma yöntemi ile veri kümesinin ön işleme tabi tutulması sonucu işlenmiş veri kümesi 16 özelliğe sahip olarak belirlenmiş ve 7 özellik sınıflandırma dışı bırakılmıştır.

Üç farklı ayrıklaştırma yöntemine ait işlenmiş veri kümesini kullanan en uygun DVM modellerine ait RBF çekirdek parametreleri, eğitim hataları ve sınıflandırma başarıları tüm özelliklerin indirgenmeden kullanıldığı DVM modelindeki (Bölüm 5.2) sonuçlarla karşılaştırmalı olarak Tablo 5.5'te verilmiştir.

Tablo 5.5 Ayrıklaştırma ile ön işleme gerçekleştirilmiş DVM modellerine ve ön işleme uygulanmamış DVM modeline ait en uygun RBF çekirdek parametreleri ve sınıflandırma sonuçları

Yöntem	c	γ	**Eğitim Hatası (%)**	**Sınıflandırma Başarısı (%)**
Eşit aralığa dayalı ayrıklaştırma – DVM	2	0,25	1,04	76,04
Eşit frekansa dayalı ayrıklaştırma – DVM	8	0,03125	2,96	76,45
Entropi tabanlı ayrıklaştırma – DVM	4	1	3,64	76,67
DVM	8	1	0,31	76,67

5.6. KAH'nın YBTS ile Teşhisi

Tez çalışmasında EST verilerine bağlı olarak KAH teşhisinde gerçekleştirilen bir diğer uygulamada EST verileri YBTS yöntemi ile sınıflandırılmıştır.

Buna göre 480 bireye ait 23 özelliğin bulunduğu EST veri kümesi [-1,1] arasına normalleştirilmiştir. YBTS'ne ait parametrelerden mutasyon oranı, hipermutasyon oranı, uyarma eşiği ve hafıza hücrelerinin sınıflandırılması aşamasında K-NN yönteminde kullanılan *k* komşuluk parametresi sırasıyla 0.1, 3, 0.9 ve 5 olarak kullanılmıştır. Bununla birlikte klonlama oranı, kaynak sayısı ve duyarlılık eşik ölçüsü parametreleri Tablo 5.6'da belirtilen aralıkta değiştirilerek en uygun YBTS modeli elde edilmiştir. En uygun YBTS modelinde klonlama oranı, kaynak sayısı ve duyarlılık eşik ölçüsü sırasıyla 1.5, 100 ve 0.95 olarak elde edilmiştir. Yöntemde ayrıca veri kümesi 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır ve %5'den daha büyük eğitme hatasına modeller uygunsuz olarak kabul edilmiştir.

Tablo 5.6 YBTS parametre optimizasyon aralıkları

Parametre	Başlangıç Değeri	Bitiş Değeri	Artış Miktarı
Klonlama Oranı	1	5	0,5
Kaynak Sayısı	100	500	50
Duyarlılık Eşik Ölçüsü	0,55	0,95	0,05

KAH teşhisinde EST verilerinin en uygun YBTS modeline göre değerlendirilmesi sonucu elde edilen tanısal doğruluk değeri (sınıflandırma başarısı), duyarlılık, özgüllük, pozitif tahmin ettirici değer, negatif tahmin ettirici değer, ROC

eğrisi altında kalan alan ve sınıflandırma sonuçlarının KAG sonuçları ile arasındaki Cohen'in Kappa katsayısı Tablo 5.7'de verilmiştir.

Tablo 5.7 En uygun YBTS modeline göre sınıflandırma sonuçları

Yöntem	TD (%)	DUY (%)	ÖZG (%)	PTD (%)	NTD (%)	AROC	κ
YBTS	76.46	86.40	53.92	81.52	57.94	0,7098	0.362

TD, Tanısal doğruluk; DUY, Duyarlılık; ÖZG, Özgüllük; PTD, Pozitif tahmin ettirici değer; NTD, Negatif tahmin ettirici değer; AROC, ROC eğrisi altında kalan alan, κ, Cohen'in Kappa Katsayısı

5.7. KAH'nın PSO-K-NN ile Teşhisi

Tez çalışmasında EST verilerine bağlı olarak KAH teşhisinde gerçekleştirilen bir diğer uygulamada EST verileri PSO-K-NN ve K-NN yöntemleri ile sınıflandırılmıştır.

Buna göre 480 bireye ait 23 özelliğin bulunduğu EST veri kümesi [-1,1] arasına normalleştirilmiştir. PSO-K-NN yöntemine göre, normalleştirilmiş veri kümesinden elde edilen eğitim kümesi kullanılarak her bir sınıfa ait (hasta ve sağlıklı) bir optimum merkezi parçacık elde edilmiş ve test kümesi, elde edilen bu parçacıklar ve K-NN yöntemi ile sınıflandırılmıştır. Burada, parçacıklara ait hızı sınırlandıran v_{mak} ve $v_{\min}$ parametreleri sırasıyla 6 ve -6 olarak, atalet ağırlığı eşitlik 4.4'e göre ve c_1 ve c_2 katsayılarının her ikisi de 2 olarak kullanılmıştır. En uygun merkezi parçacıkların sınıflandırılmasında kullanılan K-NN'nin k komşuluk parametresi ise 1 olarak kullanılmıştır. Yöntemde ayrıca veri kümesi 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır ve %5'den daha büyük eğitme hatasına modeller uygunsuz olarak kabul edilmiştir.

Uygulamada, parçacık sayısı ve iterasyon sayısı Tablo 5.7'de belirtilen aralıkta değiştirilerek en uygun PSO-K-NN sınıflandırma modeli elde edilmiştir. Elde edilen en uygun PSO-K-NN modeli 150 iterasyon adımına ve 65 parçacığa sahip model olarak belirlenmiştir.

PSO-K-NN yönteminin başarısını karşılaştırmak amacıyla [-1,1] aralığına normalleştirilmiş EST veri kümesi kolay ve basit bir sınıflandırıcı olan K-NN yöntemi ile de ayrıca sınıflandırılmıştır. K-NN yöntemi için *k* komşuluk parametresi 5 olarak alınarak sınıflandırma gerçekleştirilmiştir. Bu yöntemde de yine veri kümesi 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmış ve %5'den daha büyük eğitme hatasına sahip modeller uygunsuz olarak kabul edilmiştir.

Uygulama sonucunda elde edilen en uygun PSO-K-NN ve K-NN modelleri ile Bölüm 5.6'deki en uygun YBTS modeline ait tanısal doğruluk değeri (sınıflandırma başarısı), duyarlılık, özgüllük, pozitif tahmin ettirici değer, negatif tahmin ettirici değer, ROC eğrisi altında kalan alan ve sınıflandırma sonuçlarının KAG sonuçları ile arasındaki Cohen'in Kappa katsayısı Tablo 5.8'de verilmiştir.

Tablo 5.8 En uygun PSO-K-NN, K-NN ve YBTS modellerine göre sınıflandırma sonuçları

Yöntem	TD (%)	DUY (%)	ÖZG (%)	PTD (%)	NTD (%)	AROC	κ
PSO-K-NN	92.49	97.39	79.94	92.87	93.13	0.8956	0.806
K-NN	72.71	79.19	55.97	82.28	51.02	0.7660	0.341
YBTS	76.46	86.40	53.92	81.52	57.94	0.7098	0.362

TD, Tanısal doğruluk; DUY, Duyarlılık; ÖZG, Özgüllük; PTD, Pozitif tahmin ettirici değer; NTD, Negatif tahmin ettirici değer; AROC, ROC eğrisi altında kalan alan; κ, Cohen'in Kappa Katsayısı

5.8. KAH'nın Teşhisinde YSA ve DVM Yöntemlerinin Karşılaştırılması

Tez çalışmasında EST verilerine bağlı olarak KAH teşhisinde gerçekleştirilen bir diğer uygulamada EST verileri YSA ve DVM yöntemleri ile sınıflandırılmıştır.

Buna göre 480 bireye ait 23 özelliğin bulunduğu EST veri kümesi [-1,1] arasına normalleştirilmiştir. Uygulamada YSA modeli olarak geriye yayılım eğitim algoritmasını kullanan ÇKYSA modeli kullanılmıştır. Model, bir giriş katmanı bir gizli katman ve bir çıkış katmanı içermektedir. Gizli katmanda tanjant sigmoid, çıkış katmanında logaritmik sigmoid transfer fonksiyonu kullanılmıştır. Logaritmik sigmoid fonksiyonu kullanılan çıkış katmanındaki değerler test aşamasında 0 ya da 1'e yuvarlanarak bireyde KAH'nın bulunup bulunmadığını göstermektedir.

En optimum YSA modelini bulmak amacıyla öğrenme katsayısı (lr), momentum katsayısı (mc), gizli katmandaki nöron sayısı ve iterasyon sayısı Tablo 5.9'da belirtilen aralıkta değiştirilerek modeller test edilmiştir. Yöntemde ayrıca veri kümesi 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır ve %5'den daha büyük eğitme hatasına modeller uygunsuz olarak kabul edilmiştir. Buna göre, elde edilen en uygun YSA modelinde öğrenme katsayısı 0.1, momentum katsayısı ise 0.9 olarak elde edilmiştir. Bu model gizli katmanda 75 nörona sahip olup iterasyon sayısı 3000 olarak elde edilmiştir.

Tablo 5.9 YSA parametre optimizasyon aralıkları

Parametre	Başlangıç Değeri	Bitiş Değeri	Artış Miktarı
Öğrenme Katsayısı	0.1	0.5	0.1
Momentum Katsayısı	0.5	0.9	0.1
Gizli Katmandaki Nöron Sayısı	5	200	5
İterasyon Sayısı	1000	10000	1000

KAH'nın DVM ile sınıflandırılmasında [-1,1] aralığına normalleştirilmiş veri kümesi en uygun modelin elde edilmesi amacıyla lineer, polinomal ve RBF çekirdeklere sahip modellerde ayrı ayrı değerlendirilmiştir. Buna göre her bir çekirdeğe ait parametreler Tablo 5.10'da verilen çekirdek parametreleri optimizasyon aralıklarına göre değerlendirilmiştir. Yöntemde ayrıca veri kümesi 5-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmıştır ve %5'den daha büyük eğitme hatasına modeller uygunsuz olarak kabul edilmiştir. Elde edilen en uygun DVM modeli RBF çekirdeğe sahip bir model olup c ve γ parametreleri sırasıyla 0.4 ve 10 olarak bulunmuştur.

Tablo 5.10 DVM parametre optimizasyon aralıkları

Çekirdek	Parametre	Başlangıç Değeri	Bitiş Değeri	Artış Miktarı
Lineer	c	1	10	1
Polinomal	d	1	5	1
Polinomal	γ	0	1	0.1
Polinomal	r	0	5	1
Polinomal	c	1	100	1
RBF	γ	0	5	0.1
RBF	c	1	100	1

En uygun YSA modeli için eğitim hatası ve test başarısı sırasıyla %1.86, %78.13 olarak elde edilirken en uygun DVM modeli için eğitim hatası ve test başarısı sırasıyla %1.30, %79.17 olarak elde edilmiştir. EST verilerinin KAH teşhisinde uzmanların geleneksel değerlendirmelerine ve ayrıca en uygun YSA ve DVM modeline ait tanısal doğruluk değeri (sınıflandırma başarısı), duyarlılık, özgüllük, pozitif tahmin ettirici değer, negatif tahmin ettirici değer ve sınıflandırma sonuçlarının KAG sonuçları ile arasındaki Cohen'in Kappa katsayısı Tablo 5.11'de verilmiştir.

Tablo 5.11 Uzman Hekimlerin değerlendirmeleri ile en uygun YSA ve DVM modellerine ait sınıflandırma sonuçları

Yöntem	TD (%)	DUY (%)	ÖZG (%)	PTD (%)	NTD (%)	κ
Uzman Hekim	68.33	78.03	43.28	78.03	43.28	0.213
DVM	79.17	84.76	63.98	86.70	59.69	0.473
YSA	78.13	86.35	59.64	83.42	60.23	0.411

TD, Tanısal doğruluk; DUY, Duyarlılık; ÖZG, Özgüllük; PTD, Pozitif tahmin ettirici değer; NTD, Negatif tahmin ettirici değer; κ, Cohen'in Kappa Katsayısı

KAH'nın teşhisi konusunda EST verilerinin yapay zeka yöntemleri ile değerlendirildiği çalışmalara ait elde edilen tüm sonuçların karşılaştırılması Tablo 5.12'de verilmiştir. Sonuçlar incelendiğinde tüm yapay zeka yöntemlerinin hekim değerlendirme sonuçlarından daha iyi sonuçlar verdiği gözlemlenmiştir. EST verilerinin ön işleme uygulanmadan değerlendirildiği ya da EST verileri üzerinde özellik seçimi gerçekleştirilmediği uygulamalara bakıldığında DVM'nin YSA, YBTS ve K-NN yöntemlerinden daha iyi sonuçlar verdiği gözlemlenmiştir. Bununla birlikte PSO-K-NN yöntemi KAH'nın teşhisinde referans olarak kabul edilen KAG sonuçlarına çok iyi bir uyum ile (**κ**=0,806) oldukça yüksek duyarlılık, özgüllük ve tanısal doğruluk oranlara sahip olarak en iyi sınıflandırma sonucuna sahip olduğu gözlemlenmiştir. Ayrıca, gerçekleştirilen tüm yöntemlerin, EST verilerine bağlı olarak KAH'nın teşhisi konusunda hekimler tarafından konvansiyonel yöntemlerle elde edilen duyarlılık ve özgüllük değerlerine eşit ya da daha yüksek değerlere sahip olarak sınıflandırma işlemini başarıyla gerçekleştirdikleri gözlemlenmiştir. Gerçekleştirilen tüm uygulamalarda sınıflandırıcılarla birlikte ön işleme ve özellik seçim yöntemlerinin kullanılmasının sınıflandırma başarısını artırdığı gözlemlenmiştir.

Tablo 5.12 Uzman Hekimlerin değerlendirmeleri ile en uygun YSA ve DVM modellerine ait sınıflandırma sonuçları

Yöntem	EH (%)	TD (%)	DUY (%)	ÖZG (%)	PTD (%)	NTD (%)	AROC	κ
DVM	0,31	76,67						
İPSO-DVM	0,26	81,46						
GA-DVM	0,00	79,17						
PSO-K-NN	<5	92.49	97.39	79.94	92.87	93.13	0.8956	0.806
K-NN	<5	72.71	79.19	55.97	82.28	51.02	0.7660	0.341
YBTS	<5	76.46	86.40	53.92	81.52	57.94	0.7098	0.362
TBA-18-DVM	0,05	79,17						
EAA – DVM	1,04	76,04						
EFA – DVM	2,96	76,45						
EntA – DVM	3,64	76,67						
UHD	<5	68.33	78.03	43.28	78.03	43.28		0.213
DVM(2)	<5	79.17	84.76	63.98	86.70	59.69		0.473
YSA	<5	78.13	86.35	59.64	83.42	60.23		0.411

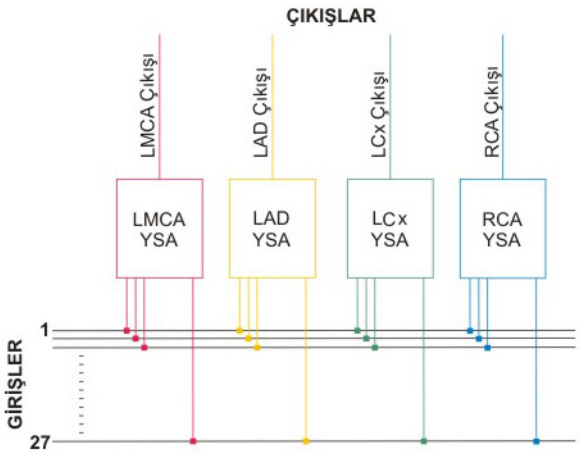
EH, Eğitim Hatası; TD, Tanısal doğruluk; DUY, Duyarlılık; ÖZG, Özgüllük; PTD, Pozitif tahmin ettirici değer; NTD, Negatif tahmin ettirici değer; AROC, ROC eğrisi altında kalan alan; κ, Cohen'in Kappa Katsayısı; EAA-DVM, Eşit aralığa dayalı ayrıklaştırma - DVM; EFA-DVM, Eşit frekansa dayalı ayrıklaştırma - DVM; EntA-DVM, Entropi tabanlı ayrıklaştırma - DVM; UHD, Uzman hekim değerlendirmesi.

5.9. KAH ve Lezyon Lokalizasyonu Teşhislerinde YSA kullanımı

Tez çalışmasında EST verilerine bağlı olarak KAH ve lezyon lokalizasyonu teşhislerinde gerçekleştirilen bir diğer uygulamada EST verileri YSA yöntemi ile değerlendirilmiştir (Babaoğlu ve ark. 2009b).

KAH ve Lezyon Lokalizasyonları teşhisi konusunda gerçekleştirilen bu çalışmada uzman hekimlerin bilgilerine dayanarak istirahat halindeki sistolik ve diyastolik kalp basınçları ile peak aşamasındaki sistolik ve diyastolik kalp basınçları da kaydedilmiş olan bireylere ait EST veri kümesi içerisindeki 480 hastadan 330'u çalışmaya dahil edilmiştir. Buna göre 330 bireye ait 27 özelliğin bulunduğu EST veri kümesi *z-score* metoduna göre normalleştirilmiştir.

Bu uygulamada, YSA modeli olarak geriye yayılım eğitim algoritmasını kullanan ÇKYSA modeli kullanılmıştır. Ana koroner arterlere bağlı olarak LMCA, LAD, LCx ve RCA için birbirinden farklı 4 YSA modeli oluşturulmuştur. Oluşturulan modellerin her biri ait olduğu damarda bir lezyonun olup olmadığını belirtmekte iken bu damarlardan herhangi birinde lezyon olması durumu KAH'nın varlığını göstermektedir. Bir başka deyişle dört farklı YSA'nın çıkışlarının lojik *OR* işlemine tabi tutulması KAH'nın varlığını göstermektedir. Tüm YSA modelleri aynı eğitim ve test kümesi kullanılarak eğitilmiş ve test edilmiştir. Ancak her bir YSA modeli eğitim ve test aşamasında ait olduğu damara ait lezyon var ya da yok şeklinde ikili değerden oluşan tek boyutlu bir çıkış vektörü kullanmaktadır. Uygulamada oluşturulan teşhis sisteminin yapısı Şekil 5.6'da verilmiştir.



Şekil 5.6 Oluşturulan Ağ yapısı

Oluşturulan YSA modellerinin her biri tek bir gizli katman içermekte olup 3000 iterasyon boyunca, öğrenme katsayısı (lr) 0.1 ve momentum katsayısı (mc) da 0.8 kabul edilerek eğitilmiştir. Her bir YSA modelinin giriş katmanında 27 nöron çıkış katmanında ise 1 adet nöron bulunmakta olup tüm modellerde gizli katmanda tanjant sigmoid, çıkış katmanında logaritmik sigmoid transfer fonksiyonu kullanılmıştır. Logaritmik sigmoid fonksiyonu kullanılan çıkış katmanındaki değerler

test aşamasında 0 ya da 1'e yuvarlanarak YSA'nın ait olduğu damarda lezyonun bulunup bulunmadığını göstermektedir.

KAH ve lezyon lokalizasyonu teşhislerinde her bir ana koroner arterdeki lezyonun sınıflandırılmasını sağlayan YSA modelleri içinden optimumum YSA modelinin bulunması amacıyla gizli katmanlarda bulunan nöronlar [10,250] aralığında 10 birim artış ile kullanılarak değerlendirilmişlerdir. Bu yöntemde de yine her bir YSA modeli için veri kümesi 10-fold çapraz doğrulama yöntemi kullanılarak sınıflandırılmış ve %5'den daha büyük eğitme hatasına sahip modeller uygunsuz olarak kabul edilmiştir. Ana koroner arterlerin teşhisinde kullanılan 4 farklı optimum YSA'ya ait tanısal doğruluk değeri (sınıflandırma başarısı), duyarlılık, özgüllük, pozitif tahmin ettirici değer, negatif tahmin ettirici değer, eğitim hatası ve optimum YSA'daki gizli katmanda bulunan nöron sayısı Tablo 5.13'te verilmiştir.

Tablo 5.13 Ana koroner arterlere ait en uygun YSA modellerine göre sınıflandırma sonuçları

YSA Modeli	Nöron	TD (%)	DUY (%)	ÖZG (%)	PTD (%)	NTD (%)
LMCA-YSA	180	91,21	25,00	96,69	30,00	93,96
LAD-YSA	210	73,03	75,33	69,61	72,78	70,82
LCx-YSA	240	64,85	50,29	74,52	54,16	70,62
RCA-YSA	40	69,39	49,90	79,54	59,17	73,77

Nöron, Gizli katmandaki nöron sayısı; TD, Tanısal doğruluk; DUY, Duyarlılık; ÖZG, Özgüllük; PTD, Pozitif tahmin ettirici değer; NTD, Negatif tahmin ettirici değer; κ, Cohen'in Kappa Katsayısı;

6. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında çeşitli yapay zeka ve makine öğrenmesi teknikleri ile EST verilerine bağlı olarak KAH'nın varlığının ve olası bir lezyonun tespit edilmesine çalışılmıştır. Gerçekleştirilen tüm uygulamalarda modelin güvenilirliğinin artırılması amacıyla *k*-fold çapraz doğrulama kullanılmıştır. Bununla birlikte uygulamalarda, %5'den daha büyük eğitim hatasına sahip tüm modeller uygunsuz olarak kabul edilmiş ve genel değerlendirmeye alınmamıştır. Gerçekleştirilen tüm uygulamalarda en uygun modelin belirlenmesi amacıyla uygulamaya özel bazı parametrelerin optimizasyonuna çalışılmıştır.

EST verilerine bağlı olarak KAH'nın teşhisinde gerçekleştirilen uygulamalarda temel olarak DVM, YBTS, PSO-K-NN ve K-NN ve YSA yöntemleri kullanılmıştır. DVM ile gerçekleştirilen ilk uygulamada yöntemde kullanılan RBF çekirdeğe ait parametreler optimize edilerek en uygun model belirlenmeye çalışılmıştır. Elde edilen en uygun model %76,67 sınıflandırma başarısına sahiptir.

DVM yönteminin sınıflandırma başarısını artırmak amacıyla EST verisine PSO ve GA algoritmaları kullanılarak özellik seçimi gerçekleştirilmiş ve TBA ve ayrıklaştırma ön işleme yöntemleri uygulanmıştır. Buna göre, PSO ve GA algoritmaları kullanarak EST verisinde gerçekleştirilen özellik seçimi sonucu elde edilen en uygun DVM modelinin sınıflandırma başarısı sırasıyla %81,46 ve %79,17 olarak bulunmuştur. EST verilerinin TBA yöntemi ile indirgendiği uygulamaya göre en uygun modelde indirgenen verinin DVM ile sınıflandırması sonucu elde edilen sınıflandırma başarısı %79,17 olarak elde edilmiştir. EST verilerinin üç farklı ayrıklaştırma yönteminin kullanılarak değerlendirildiği uygulamada ise en uygun model entropy ayrıklaştırma modeli olurken ayrıklaştırılmış EST verisinin DVM ile sınıflandırılması sonucu elde edilen sınıflandırma başarısı %76,67 olarak elde edilmiştir. Ancak, her üç model ile ayrıklaştırılan EST verisinin en uygun DVM modelleri ile sınıflandırılması sonucu birbirine çok yakın ve EST verilerinin ön işleme olmadan DVM ile sınıflandırılmasına eşit sınıflandırma başarıları elde edilmiştir.

EST verilerinin KAH'nın teşhisi konusunda YBTS ile değerlendirildiği uygulamada da YBTS'ne ait çeşitli parametreler optimize edilmeye çalışılmıştır. En uygun YBTS modelinde sınıflandırma başarısı %76.46 olarak elde edilmiştir.

EST verilerinin KAH'nın teşhisi konusunda PSO-K-NN ile değerlendirildiği uygulamada en uygun PSO-K-NN modelinin sınıflandırma başarısı ise %92.49 olarak elde edilmiştir. Özellikle PSO-K-NN sınıflandırıcısı ile karşılaştırmak amacıyla EST verileri basit ve hızlı bir yöntem olan K-NN yöntemi ile de değerlendirilmiş ve bu yönteme ait sınıflandırma başarısı da %72.71 olarak elde edilmiştir.

YSA kullanılarak EST verilerine bağlı KAH'nın teşhisi konusunda gerçekleştirilen sınıflandırma uygulamasında en uygun YSA modelinin sınıflandırma başarısı %78.13 olarak elde edilmiştir. Bu uygulamada, en uygun YSA modelinin elde edilmesi amacıyla YSA'nın parametreleri de optimize edilmiştir. YSA ile DVM yöntemlerinin sınıflandırma başarılarını karşılaştırmak amacıyla DVM, birden fazla çekirdeğe ve farklı parametre aralıklarına göre EST verileri üzerinde tekrar uygulanmıştır. Burada en uygun DVM modelinin RBF çekirdeğe sahip olduğu görülmektedir. Ayrıca, bu yöntemin sınıflandırma başarısı da % 79.17 olarak elde edilmiştir.

EST verilerine bağlı KAH'nı teşhisi konusunda gerçekleştirilen sınıflandırma uygulamalarının yanı sıra lezyon lokalizasyonunun tespiti konusunda gerçekleştirilen bir diğer uygulamada LMCA, LAD, LCx ve RCA koroner arterleri için ayrı ayrı 4 farklı YSA modeli optimize edilmeye çalışılmıştır. Uygulamada LMCA, LAD, LCx ve RCA koroner arterleri için elde edilen en uygun YSA modelleri lezyonun modele ait damarda bulunduğunu tespit ederken bu modellerden herhangi birinde lezyonun olması durumu ise KAH'nın varlığı olarak kabul edilmiş ve uygulamada bu dört YSA modeli birlikte değerlendirilmiştir. Buna göre LMCA, LAD, LCx ve RCA koroner arterleri için en uygun YSA modellerinden elde edilen sınıflandırma başarıları sırasıyla % 91.25, % 73.03, % 64.85 ve % 69.39 olarak bulunmuştur.

EST'nin uzman kardiyologlar tarafından KAH teşhisi konusunda geleneksel yöntemlerle değerlendirilmesine bakıldığında, hekim değerlendirmesi sonucu elde edilen tanısal doğruluk oranının % 68.33 olarak elde edildiği görülmektedir.

EST verilerine bağlı olarak KAH'nın teşhisi konusunda gerçekleştirilen uygulamalara ait sonuçlar değerlendirildiğinde elde edilen tüm sonuçların EST verilerinin uzman hekimlerin tarafından geleneksel yöntemlerle değerlendirmesinden daha yüksek tanısal doğruluk oranına sahip oldukları görülmüştür. Buna göre uygulamaların pratikte hekimlerin değerlendirmelerine ek olarak kullanılabileceği ve KAH'nın teşhisi konusundaki başarıyı artırabileceği gözlemlenmiştir.

Bunun yanı sıra, EST verilerine bağlı olarak KAH'nın teşhisi konusunda DVM yönteminin YSA'dan daha başarılı sonuçlar verdiği görülmektedir. Ayrıca, Bölüm 5.9'da gerçekleştirilen uygulama sonuçlarına göre hem DVM hem de YSA'nın sınıflandırma modellerinin Kappa katsayısına bakıldığında hekim değerlendirme sonuçlarından daha güvenilir olduğu gözükmektedir. Bununla birlikte, PSO-K-NN yönteminin sınıflandırma sonuçlarına bakıldığında 0.8 değerindeki kapa değeri ile modelin KAG sonuçlarına hemen hemen mükemmel bir uyum ile bağlı olduğu gözükmektedir.

EST verilerine bağlı olarak KAH'nın teşhisi konusunda PSO-K-NN yöntemi kullanılarak gerçekleştirilen uygulama çalışmadaki en iyi sonuca sahip uygulamadır. % 92.49'luk bir başarı oranına sahip bu yöntem % 97.39 duyarlılık ve %79.94 özgüllük değerlerine sahip olup KAG sonuçlarına en yakın sonuç verdiği Kappa değeri ile de vurgulanan bir yöntemdir.

YSA yöntemi ile gerçekleştirilen EST verilerine bağlı olarak KAH'nın varlığı ve lezyon lokalizasyonunun tespiti konusundaki çalışma, elde edilen uygulama sonuçlarına göre literatürde lezyon lokalizasyonu konusunda geleneksel yöntemlerle gerçekleştirilen çalışmalara ait duyarlılık ve özgüllük değerlerinden daha yüksek değerlere sahip olarak modelin pratikte hekimlere destek amaçlı kullanılabilir özellikte olduğunu göstermiştir.

Bu tez çalışmasında gerçekleştirilen uygulamaların başarısını daha da artırmak amacıyla özellik seçim yöntemlerinin ön işleme yöntemleri ile birlikte kullanıldığı uygulamalar gerçekleştirilebilir. Uygulamalarda kullanılan yöntemlere ve bu yöntemlere ait modellere bakıldığında, KAH'nın teşhisi konusunda en iyi sonuç veren yöntemin PSO-K-NN yöntemi olduğu gözlemlenmiştir. Bu yüzden, PSO-K-NN yönteminin işleyişi de dikkate alındığında, EST verileri üzerinde

gerçekleştirilecek bir kümeleme işlemi, başarıyı artırıcı bir ön işlem olarak kullanılabilecektir. Ayrıca, EST verilerinin ağırlıklandırılarak sınıflandırılması da başarıyı artırmak amacıyla kullanılabilecektir. Lezyon lokalizasyonu konusunda gerçekleştirilen uygulama da yine ağırlıklandırma ile değerlendirilebilir. Uygulamalarda kullanılan PSO yöntemi yerine farklı bir evrimsel algoritmanın başarısı araştırılabilir.

KAYNAKLAR

Agresti, A. 2007. An introduction to categorical data analysis, 2nd ed. Wiley.

An, S., Liu, W., Venkatesh, S. 2007. Fast cross-validation algorithms for least squares support vector machine and kernel ridge regression. Pattern Recognition.
40 : 2154-2162.

Antanavicius, K., Bastys, A., Bluzas, J., Gargasas, L., Kaminskien, S., Urbonavicien, G., et al. 2008. Nonlinear dynamics analysis of electrocardiograms for detection of coronary artery disease. Computer Methods and Programs in Biomedicine.
92 : 198-204.

Avci, E. 2009. A new intelligent diagnosis system for the heart valve diseases by using genetic-SVM classifier. Expert Systems with Applications. 36 : 10618-10626.

Babaoğlu, İ., Fındık, O., Ülker, E. 2010. A comparison of feature selection models utilizing binary particle swarm optimization and genetic algorithm in determining coronary artery disease using support vector machine. Expert Systems with Applications. 37(4) : 3177-3183.

Babaoğlu, İ., Fındık, O., Bayrak, M. 2010. Effects of principle component analysis on assessment of coronary artery diseases using support vector machine. Expert Systems with Applications. 37(3) : 2182-2185.

Babaoğlu, İ., Fındık, O., Ülker, E. 2009. Effects of discretization on determination of coronary artery disease using support vector machine. Proceedings of the 2nd International Conference on Interaction Sciences: Information Technology, Culture and Human, ICIS 2009. vol 2, pp 726-729. Seoul, Korea.

Babaoğlu, İ., Baykan, O.K., Aygül, N., Özdemir, K., Bayrak, M. 2009. Assessment of exercise stress testing with artificial neural network in determining coronary artery disease and predicting lesion localization. Expert Systems with Applications. 36 : 2562-2566.

Baykan, Ö.K. 2007. Bilgisayar destekli un kalite izleme sistemi tasarımı. Doktora Tezi, Fen Bilimleri Enstitüsü, Konya.

Berke, A.D. Cardiac consultation and interventional cardiology.
http://www.cardiology.md/procedures.htm, Son erişim 01.06.2010

Burges, C.J. 1998. A tutorial on support vector machines for pattern recognition. Data Mining and Knowledge Discovery. 2(2) : 121-167.

Ceylan, M., Ceylan, R., Dirgenali, F., Kara, S., Ozbay, Y. 2007. Classification of carotid artery doppler signals in the early phase of atherosclerosis using complex-valued artificial neural network. Computers in Biology and Medicine. 37 : 28-36.

Ceylan, R., Özbay, Y. 2007. Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network. Expert Systems with Applications. 33(2) : 286-295.

Chang, C.-C., Lin, C.-J. 2001. LIBSVM: A library for support vector machines. http://www.csie.ntu.edu.tw/~cjlin/libsvm, Son erişim: 01.06.2010

Chaitman, B.R. 2005. Exercise Stress Testing. Braunwald's Heart Disease, 7th ed. Zipes, D.P., Libby, P., Bonow, R.O., Braunwald, E. (ed). Elsevier, Saunders, Pennsylvania.

Cios, K.J., Goodenday, L.S., Sztandera, L.M. 1994. Hybrid intelligence system for diagnosing coronary stenosis. Combining fuzzy generalized operators with decision rules generated by machine learning algorithms. IEEE Engineering in Medicine and Biology Magazine. 13(5) : 723-729.

Çolak, M.C., Çolak, C., Kocatürk, H., Sağıroğlu, Ş., Barutçu, İ. 2008. Predicting coronary artery disease using different artificial neural network models. Anadolu Kardiyoloji Dergisi. 8 : 249-254.

Çomak, E. 2008. Destek vektör makinelerinin etkin eğitimi için yeni yaklaşımlar. Doktora Tezi, Fen Bilimleri Enstitüsü, Konya.

Çomak, E., Arslan, A., Türkoğlu, İ. 2007. A decision support system based on support vector machines for diagnosis of the heart valve diseases. Computers in Biology and Medicine. 37 : 21-27.

Cormen, T.H., Leiserson, C.E., Rivest, R.L., Stein, C. 2001. Introduction to algorithms. 2nd edition. MIT Press.

De Falco, I., Della Cioppa, A., Tarantino, E. 2006. Evaluation of particle swarm optimization effectiveness in classification. Lecture Notes in Computer Science. 3849 : 164-171.

Dougherty, J., Kohavi, R., Sahami, M. 1995. Supervised and unsupervised discretization of continuous features. Proceedings of the 12th international conference on machine learning. 194–202.

Duda, R.O., Hart, P.E., Stork, D.G. 2001. Pattern classification. John Wiley & Sons, New York.

Elavunkal, J., Sinert, R.H. 2007. Screening and Diagnostic Tests. http://emedicine.medscape.com/article/773832-overview, Son erişim: 01.06.2010

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

Fayyad, U., Irani, K. 1993. Multi-interval discretization of continuous-valued attributes for classification learning. 13th International Joint Conference on Artificial Intelligence. 1022-1027.

Fukunaga, K. 1990. Introduction to Statistical Pattern Recognition. 2nd ed. Academic Press, New York.

Gallik, D.M., Mahmarian, J. J., Verani, M.S. 1993. Therapeutic Significance of Exercise-Induced ST-Segment Elevation in Patients Without Previous Myocardial Infarction. American Journal of Cardiology. 72 : 1-7.

Gestal, M., Andrade, J.M. 2008. Evolutionary approaches to variable selection. Encyclopedia of Artificial Intelligence. Dopico, J.R.R, Dorado, J., Pazos, A. (ed), pp 581-588,Idea Group Publishing, Hershey, PA.

Gibbons, R.J., Balady, G.J., Bricker, J.T. 2002. ACC/AHA Guideline update for exercise testing: summary article. A report of the American college of cardiology/American heart association task force on practice guidelines (Committee to update the 1997 exercise testing guidelines). J Am Coll Cardiol. 40(8) : 1531-1540.

Gunn, S. R. 1998. Support vector machines for classification and regression. ISIS, Technical Report. University of Southampton, Department of Electrical and Computer Science.

Haykin, S. 1994. Neural Networks: A Comprehensive Foundation. Macmillan, New York.

Holland, J. 1975. Adaptation in natural and artificial systems. The Michigan University Press.

Hsu, C.N., Huang, H.J., Wong, T.T. 2003. Implications of the Dirichlet assumption for discretization of continuous variables in naive Bayesian classifiers. Machine Learning. 53(3) : 235–263.

Hsu, C.W., Lin, C.J. 2002. A Comparison of Methods for Multiclass Support Vector Machines. IEEE Transactions on Neural Networks. 13(2) : 415-425.

Jolliffe, I.T. 1986. Principal component analysis. Springer, New York.

Kannathal, N., Lim, C.M., Rajendra Acharya, U., Sadasivan, P.K. 2006. Cardiac State Diagnosis Using Adaptive Neuro-fuzzy Technique. Medical Engineering & Physics. 28(8) : 809-815.

Kennedy, J., Eberhart, R.C. 1997. A discrete binary version of the particle swarm algorithm. Proceedings of 1997 conference systems, man and cybernetics, pp 4104–4108, Piscataway, NJ.

Kennedy, J., Eberhart, R.C. 1995. Particle swarm optimization. Proceedings of IEEE international conference on neural networks. pp 1942-1948, Piscataway, NJ.

Kodaz, H. 2007. Bilgi Kazancı Tabanlı Yapay Bağışıklık Tanıma Sistemi. Doktora Tezi, Fen Bilimleri Enstitüsü, Konya.

Kurt, I., Ture, M., Kurum, A.T. 2008. Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease. Expert Systems with Applications. 34 : 366-374.

Landis, J. R., Koch, G.G. 1977. The measurement of observer agreement for categorical data. Biometrics. 33 : 159-174.

Lapuerta, P., Azen, S.P., Labree, L. 1995. Use of neural networks in predicting the risk of coronary artery disease. Computers and Biomedical Research. 28(1) : 38-52.

Lin, C.-H., Du, Y.-C., Chen, T. 2008. Adaptive wavelet network for multiple cardiac arrhythmias recognition. Expert Systems with Applications. 34(4) : 2601–2611.

Liu, H., Hussain, F., Tan, C.L., Dash, M. 2002. Discretization: An enabling Technique. Data Mining and Knowledge Discovery. 6(4) : 393-423.

Maglogiannis, I., Loukis, E., Zafiropoulos, E., Statis, A. 2009. Support Vectors Machine-based identification of heart valve diseases using heart sounds. Computer Methods and Programs in Biomedicine. 95 : 47-61.

McMahon, E.M., Korinek, J., Yoshifuku, S., Sengupta, P.P., Manduca, A., Belohlavek, M. 2008. Classification of acute myocardial ischemia by artificial neural network using echocardiographic strain waveforms. Computers in Biology and Medicine. 38(4) : 416-424.

Michalewicz, Z. 1992. Genetic Algorithms + Data Structures = Evolution Programs. Springer-Verlag, Berlin.

Mobley, B.A., Moore, W.E., Schechter, E., Eichner, J.E., McKee, P.A. 2002. Neural network predictions of significant coronary artery stenosis in women. Computational intelligence processing in medical diagnosis. Schmitt, M.,

Teodorescu, H.-N, Jain, A., Jain, A., Jain, S., Jain, L.C. (ed). Physica-Verlag, Heidelberg.

Mobley, B.A., Schechter, E., Moore, W.E., McKee, P.A., Eichner, J.E. 2005. Neural network predictions of significant coronary artery stenosis in men. Artificial Intelligence in Medicine. 34 : 151-161.

Mobley, B.A., Schechter, E., Moore, W.E., McKee, P.A., Eichner, J.E. 2000. Predictions of coronary artery stenosis by artificial neural network. Artificial Intelligence in Medicine. 18.

Nielsen, C., Lang, R.S. 1999. Principles of screening, The Medical Clinics of North America. 83(6) : 1323-1337.

Öngen, Z. 2001. Aterosklerotik Kalp Hastalıkları. Klinik Kardiyoloji. Erol Ç, Kozan Ö, Sansoy V, (ed). pp 1-19, MN Medikal & Nobel, Ankara

Özbay, Y., Ceylan, R., Karlik, B. 2006. A fuzzy clustering neural network architecture for classification of ECG arrhythmias. Computers in Biology and Medicine. 36(4) : 376-388.

Pal, S.K., Mitra, P. 2004. Pattern Recognition Algorithms for Data Mining: Scalability, Knowledge Discovery and Soft Granular Computing. Chapman & Hall, Boca Raton, FL.

Pao, Y.H. 1989. Adaptive Pattern Recognition and Neural Networks. Addison-Wesley, Reading

Polat, K. 2004. Özellik seçme (FS) ile yapay bağışıklık tanıma sistemi (AIRS) kullanılarak medikal teşhise gidiş. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Konya.

Polat, K., Güneş, S. 2007. Detection of ECG Arrhythmia using a differential expert system approach based on principal component analysis and least square support vector machine. Applied Mathematics and Computation. 186 : 898-906.

Polat, K., Şahan, S., Güneş, S. 2006. A new method to medical diagnosis: Artificial immune recognition system (AIRS) with fuzzy weighted pre-processing and application to ECG arrhythmia. Expert Systems with Applications. 31(2) : 264-269.

Rumelhart, D.E., Widrow, B., Lehr, M.A. 1994. The basic ideas in neural networks. Communications of the ACM. 37(3) : 87-92.

Sağıroğlu Ş., Beşdok E., Erler M. 2003. Mühendislikte Yapay Zeka Uygulamaları-1: Yapay Sinir Ağları. Ufuk Yayınevi, Kayseri.

San Roman, J.A., Vilacosta, I., Castillo, J.A., Rollan, M.J., Hernandez, M., Peral, V., et al. 1998. Selection of the optimal stress test for the diagnosis of coronary artery disease. Heart. 80(4) : 370-376.

Sangwook, L., Sangmoon, S., Sanghoun, O., Witold, P., Moongu, J. 2008. Modified binary particle swarm optimization. Progress in Natural Science. 18 : 1161-1166.

Serhatlioglu, S., Hardalac, F., Guler, I. 2003. Classification of Transcranial Doppler Signals Using Artificial Neural Network. Journal of Medical Systems 27 : 205-214.

Scott, J.A., Aziz, K., Yasuda, T., Gewirtz, H. 2004. Integration of clinical and imaging data to predict the presence of coronary artery disease using neural networks. Journal of Nuclear Cardiology. 11(4) : 26.

Shakhnarovish, G., Darrell, T., Indyk, P. 2005. Nearest-Neighbor Methods in Learning and Vision. MIT Press.

Shao, J. 1993. Linear model selection by cross-validation. Journal of American Statistical Association. 88 : 486-494.

Shi, Y. 2007. Particle Swarm optimization. IEEE Neural Networks Society. 8-13.

Shi, Y., Eberhart, R.C. 1998. A modified particle swarm optimizer. Proceedings of the 1998 IEEE International Conference on Evolutionary Computation, pp 69-73, Piscataway, IEEE Press, NJ.

Shi, Y., Eberhart, R.C. 1998. Parameter selection in particle swarm optimization. Proceedings of the 1998 Annual Conference on Evolutionary Computation. 591-600.

Smith, L.I. 2002. A tutorial on principle component analysis.

Sprent, P, Smeeton, N.C. 1999. Applied non-parametric statistical methods, 3rd ed. Chapman & Hall.

Süt, N., Şenocak, M. 2007. Assessment of the performances of multilayer perceptron neural networks in comparison with recurrent neural networks and two statistical methods for diagnosing coronary artery disease. Expert Systems. 24(3) : 131-142.

Tantimongcolwata, T., Naennab, T., Isarankura-Na-Ayudhyaa, C., Embrechtsc, M. J., Prachayasittikula, V. 2008. Identification of ischemic heart disease via machine learning analysis on magnetocardiograms. Computers in Biology and Medicine.
38 (7) : 817-825.

Tezel, G. 2007. Biyomedikal işaretlerin yeni bir adaptif aktivasyon fonksiyonlu yapay sinir ağı ile sınıflandırılması. Doktora Tezi, Fen Bilimleri Enstitüsü, Konya.

Thom, T., Haase, N., Rosamond, W., Howard, V.J., Rumsfeld, J., Manolio, T., et al. 2006. Heart disease and stroke statistics–2006 update: A report from the American heart association statistics committee and Stroke statistics subcommittee. Circulation. 113 : e85-e151.

Türkoğlu, İ., Arslan, A., İlkay, E. 2002. An expert system for diagnosis of the heart valve diseases. Expert Systems with Applications. 23(3) : 229-236.

Türkoğlu, İ., Arslan, A., İlkay, E. 2003. An intelligent system for diagnosis of the heart valve diseases with wavelet packet neural networks. Computers in Biology and Medicine. 33 : 319-331.

Uğuz, H., Arslan, A., Saraçoğlu, R., Türkoğlu, I. 2008. Detection of heart valve diseases by using fuzzy discrete hidden Markov model. Expert Systems with Applications. 34 : 2799-2811.

Vapnik, V. 1995. The nature of statistical learning theory.Springer, New York.

Watkins, A. 2001. AIRS: A resource limited artificial immune classifier. Master thesis, Mississippi State University.

Zhidong, Z. 2005. Noninvasive diagnosis of coronary artery disease based on instantaneous frequency of diastolic murmurs and SVM. Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference. pp 5651-5654. Shanghai, China.