



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

KALP KRİZİ KARAR DESTEK SİSTEMİ

İlknur BUÇAN KIRKBİR

YÜKSEK LİSANS TEZİ

Yrd. Doç. Dr. Burçin KURT

TRABZON - 2017



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

KALP KRİZİ KARAR DESTEK SİSTEMİ

İlknur BUÇAN KIRKBİR

YÜKSEK LİSANS TEZİ

Yrd. Doç. Dr. Burçin KURT

TRABZON - 2017

ONAY

Bu tez yüksek lisans tezi standartlarına uygun bulunmuştur.

Prof. Dr. Kemal TURHAN

Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Başkanı

Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Yüksek Lisans Öğrencisi İlknur BUÇAN KIRKBİR'in hazırladığı “**Kalp Krizi Karar Destek Sistemi**” başlıklı tez KTÜ Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca kapsamı ve bilimsel kalite yönünden değerlendirilerek yüksek lisans tezi olarak kabul edilmiştir.

Danışman: Yrd. Doç. Dr. Burçin KURT

Yüksek Lisans/Doktora Sınavı Jüri Üyeleri

Yrd. Doç. Dr. Burçin KURT

Prof. Dr. Kemal TURHAN

Yrd. Doç. Dr. Ozan KARAKİŞİ

Tarih:

Bu tez KTÜ Sağlık Bilimleri Enstitüsü Yönetim Kurulunun .../.../.... tarih ve... sayılı kararıyla onaylanmıştır.

Prof. Dr. Ali Osman KILIÇ

Sağlık Bilimleri Enstitüsü Müdürü

BEYAN

Bu tez çalışmasının KTÜ Sağlık Bilimleri Enstitüsü tez yazım kılavuzu standartlarına uygun olarak yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterildiğini ve kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

16.12.2016

İlknur BUÇAN KIRKBİR

İTHAF

Bu tez çalışmasını, bu günlere gelebilmem için hiçbir fedakârlıktan kaçınmayan, her zaman gurur duyduğum rahmetli babam Selahattin BUÇAN'a ve beni sabırla bekleyen canım oğlum Eray KIRKBİR'e ithaf ediyorum.



TEŐEKKÖR

Bu alıřmanın gerekleřtirilmesinde deęerli bilgilerini benimle paylařan, alıřmanın her ařamasında bana yol gōsteren, ok sevgili danıřman hocam Yrd. Do. Dr. Burin KURT'a, Biyoistatistik ve Tıp Biliřimi Anabilim Dalı Bařkanı deęerli hocam Prof. Dr. Kemal TURHAN'a, alıřmam boyunca benden bir an olsun yardımlarını esirgemeyen arkadařım Tuęba KURT'a, hayatımın her evresinde bana gō veren deęerli eřim Samet KIRKBİR'e ve her zaman yanımda olup, bana destek olan sevgili aileme sonsuz teőekkÖrlerimi sunarım.

İlknur BUAN KIRKBİR

İÇİNDEKİLER

	Sayfa
İç kapak Sayfası	
KABUL ve ONAY	
BEYAN	
İTHAF	
TEŞEKKÜR	
TABLolar DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
KISALTMA, SİMGE ve FORMÜLLER	xi
1. ÖZET	1
2. SUMMARY	3
3. GİRİŞ ve AMAÇ	5
4. GENEL BİLGİLER	7
4.1. Akut Koroner Sendrom	8
4.1.1. Kalp Krizi (Miyokard İnfarktüsü)	9
4.1.2. Kalp Krizi Tanısı	10
4.2. Kalp Damar Hastalıklarının Tetikleyen Risk Faktörleri	12
4.2.1. Obezite	12
4.2.2. Hipertansiyon	13
4.2.3. Diyabet	13
4.2.4. Yüksek Kan Kolesterolü	13
4.2.5. Cinsiyet	13
4.2.6. Yaş	14
4.2.7. Tütün Kullanımı	14
4.2.8. Alkol Kullanımı	14
4.2.9. Aile Öyküsü	14
4.3. Makine Öğrenmesi Yaklaşımı	14
4.3.1. Danışmanlı Öğrenme	15
4.3.2. Danışmansız Öğrenme	16
5. GEREÇ ve YÖNTEMLER	17
5.1. Destek Vektör Makineleri	17
5.1.1. Doğrusal Ayrılabilen Veriler için DVM	18

5.1.2. Doğrusal Ayrılamayan Veriler için DVM	19
5.2. Karar Ağaçları	20
5.3. Yapay Sinir Ağları	23
5.3.1. Çok Katmanlı Yapay Sinir Ağı (MLP)	26
5.4. Verilerin Hazırlanması	29
6. BULGULAR	30
6.1. Veri Setinin Analizi	30
6.2. Destek Vektör Makinesi Modeline Dair Bulguları	36
6.3. Karar Ağacı Modeline Dair Bulgular	37
6.4. Yapay Sinir Ağı Modeline Ait Bulgular	40
6.5. Geliştirilen Tanı Modellerinin Karşılaştırılması	41
7. TARTIŞMA ve SONUÇ	43
8. KAYNAKLAR	45
9. ETİK KURUL ONAYI	49
10. ÖZGEÇMİŞ	50

TABLOLAR DİZİNİ

Tablo	Sayfa
Tablo 1. Türkiye İstatistik Kurumu 2013-2014 yılı ölüm verileri	7
Tablo 2. DVM avantajları ve dezavantajları	18
Tablo 3. Karar ağaçları avantajları ve dezavantajları	23
Tablo 4. YSA kullanım alanları	28
Tablo 5. YSA avantajları ve dezavantajları	28
Tablo 6. Kalp krizi tanısı alan hastalarda kategorik değişkenlerin dağılımları	31
Tablo 7. Kalp krizi tanısı almayan hastalarda kategorik değişkenlerin dağılımları	32
Tablo 8. Kalp krizi tanısı alan hastalarda CK-MB ve HS-Troponin tanımlayıcı istatistikleri	33
Tablo 9. Kalp krizi tanısı alan hastalarda CK-MB ve HS-Troponin tanımlayıcı istatistikleri	33
Tablo 10. Kalp krizi tanısı alan ve almayan hastaların HS-Troponin ve CK-MB değerleri açısından karşılaştırılması	33
Tablo 11. Ki-kare test sonuçları	
Tablo 12. CK-MB VE HS-Troponin Kolerayson ilişkisi analizi ile değerlendirmesi	34
Tablo 13. Kernel fonksiyonları parametreleri tablosu	37
Tablo 14. Model ve gerçek sonuçların karşılaştırılması	37
Tablo 15. Model ve gerçek sonuçların karşılaştırılması	39
Tablo 16. Model ve gerçek sonuçların karşılaştırılması	40
Tablo 17. Geliştirilen modellere ait duyarlılık ve özgüllük değerleri	41

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 1. Akut koroner sendromlar	8
Şekil 2. Kalp krizi oluşum süreci	9
Şekil 3. EKG dalgaları gösterimi	12
Şekil 4. Makine öğrenmesi süreci	15
Şekil 5. Destek vektör makineleri çalışma prensibi	17
Şekil 6. Doğrusal ayıramayan verilerle DVM	19
Şekil 7. Hava tahmini karar ağacı modeli	21
Şekil 8. Biyolojik sinir hücresi yapısı	24
Şekil 9. Yapay sinir hücresinin yapısı	24
Şekil 10. Çok katmanlı yapay sinir ağı	27
Şekil 11. Deney gurubu veri seti örneği	31
Şekil 12. Kontrol gurubu veri seti örneği	31
Şekil 13. Train set örneği	35
Şekil 14. Test set örneği	35
Şekil 15. Farklı kernel fonksiyonları ile geliştirilen DVM modellerine ait performans karşılaştırması	36
Şekil 16. Kalp krizi karar destek sistemi için geliştirilen karar ağacı modeli	38
Şekil 17. Karar ağacı modeli R program özeti	39
Şekil 18. Kalp krizi karar destek sistemi için geliştirilen YSA modeli	40
Şekil 19. Geliştirilen tanı modellerinin performans karşılaştırması	42

KISALTMA, SİMGE ve FORMÜLLER

Kısaltmalar

AKS	Akut Koroner Sendromlar
BOH	Bulaşıcı Olmayan Hastalıklar
CART	Classification and Regression Tree
CHAID	Chi-Square Automatic Interaction Detector
CK-MB	Kreatin kinaz-MB
DVM	Destek Vektör Makinesi
EKG	Elektrokargiyografi
FN	False Negative
FP	False Pozitive
HT	Hiper Tansiyon
ID3	Iterative Dichotomiser 3
JAPI	Journal of The Association of Physicians of India
KM	Kardiyak marker
MI	Miyokard Infarction
MLP	Multi-Layered Perceptron
NSTEMI	Non-ST Segment Edevatın Miyokardial Infarction
STEMI	ST Elevation Miyokardial Infarction
WHO	World Health Organization
YSA	Yapay Sinir Ağları
TP	True Pozitive
TN	True Negative
QUEST	Quick, Unbiased, Efficient, Statistical Tree

Simgeler

δ	Delta
κ	Kappa
σ	Sigma

1. ÖZET

Kalp Krizi Karar Destek Sistemi

Genellikle kalp krizi olarak adlandırılan miyokard infarktüsü (MI), kalbin bir bölümünün kanlanması bozulmasıdır. Yeterli kan gitmediği için yeterli oksijen gitmeyen kalp kası hücrelerinde hasar ve kalp kası uzun süre oksijensiz kaldığında ise ölüm meydana gelebilmektedir. Miyokard infarktüsü kaynaklı ölümlerin % 50'si ilk bir saat içinde olmaktadır ve bu oran ilk 24 saat içinde % 80 'e ulaşmaktadır. MI' ye bağlı ölümlerde hastaneye taşınma ve hastanın tanı alıp tedaviye başlama süresi büyük rol oynamaktadır.

Makine öğrenmesi yaklaşımlarına dayalı matematiksel ve istatistiksel yöntemler kullanarak mevcut verilerden örüntü çıkaran bu çıkarımlarla bilinmeyene dair tahminlerde bulunabilen sınıflama algoritmaları ile sağlık alanında hekimlere yardımcı olmak amacıyla birçok hastalığın sınıflandırılması, tahminlenmesi, risk hesaplanması gibi önemli çalışmalar yapılmaktadır. Bu bağlamda yapılan tez çalışmasında miyokard infarktüsü (kalp krizi) teşhisinde hekime yardımcı olabilecek bir karar destek sisteminin geliştirilmesi amaçlanmıştır. Sistemin geliştirilmesinde makine öğrenmesi yöntemlerinden olan yapay sinir ağları (YSA), karar ağacı ve destek vektör makinesi (DVM) yöntemleri kullanılmıştır.

Çalışma kapsamında KTÜ Tıp Fakültesi Farabi Hastanesi Acil Tıp Servisine 2014-2016 yılları arasında göğüs ağrısı şikayeti ile başvuran ve miyokard infarktüsü (MI) tanısı alan ve MI tanısı almayan 350 hasta verisi kullanılmıştır. Bu hasta verileri uzman hekim danışmanlığında biyokimya laboratuvar test sonuçları, epikriz raporları ve anjiyografi raporları sonuçları incelenerek elde edilmiştir. Cinsiyet, CK-MB (kalp kreatin kinaz), HS-Troponin I (high sensitive troponin I) ve EKG giriş verileri kullanılarak akıllı bir kalp krizi karar destek sistemi geliştirilmiştir. CK-MB ve troponin seviyelerini yükselten polimiyozit/dermatomiyozit (kaslarda iltihaplanma), müküler distrofiler (kas hastalığı), kronik böbrek yetmezliği ve kronik hemodiyaliz hastaları, son 24 saat içinde intramusküler (kas içi) enjeksiyon yapılmış olan ve son 3 gün içinde travma veya iskelet kası hasarı geçirmiş hastalar vs. gibi durumlar çalışma dışı tutulmuştur. Veriler rastgele eğitim ve test seti olmak üzere iki guruba ayrıldıktan sonra, eğitim setindeki 205 hasta verisi kullanılarak YSA, karar ağacı ve DVM yöntemleri

yardımıyla üç farklı karar destek sistemi modeli geliştirilmiştir. 145 test verisi üzerinde; DVM modeli için % 79 duyarlılık, % 83 özgüllük değerleri elde edilirken; karar ağacı modeli için % 91,7 duyarlılık, %97,9 özgüllük ve YSA modeli için ise % 98 duyarlılık, % 93 özgüllük değerleri elde edilmiştir. Bu tez çalışmasında geliştirilen üç farklı karar destek modelinden, YSA modelinin % 98 duyarlılık ile en başarılı sonucu verdiği görülmüştür.

Anahtar Sözcükler: Destek vektör makinesi, kalp krizi, karar ağacı, karar destek sistemi, makine öğrenmesi, yapay sinir ağları



2. SUMMARY

Heart Attack Decision Support System

Myocardial infarction (MI) which is generally named as heart attack is destroyed a part of heart's blood build up. In the heart muscle cells which cannot get enough oxygen because of not getting enough blood, damage may occur and if heart muscle stay without oxygen for a long time, death may occur. Fifty percent of deaths which are from the heart attack happen in first one hour and this ratio swells to eighty percent in first twenty four hours. Duration of treatment and transportation of patient to the hospital play a big role in deaths which are from the MI.

With classification algorithms which extracts patterns from existing datas and able to estimate about unknowns by using mathematical and statistical methods based on the machine learning approaches, important studies such as classification, prediction and risk calculation of a lot diseases have been made in medical area to help to doctors. In this context, development of a decision support system has been aimed to help doctors in the diagnosis of the myocardial infarction in this thesis study. In the development of the system, artificial neural networks (ANN), decision trees, support vector machine (SVM) methods have been used which are methods of the machine learning.

In the scope of the study, datas of 350 patients which had applied with chest pain complainment at Farabi hospital emergency service of medicine faculty of Karadeniz Technical University in 2014-2016, were diagnosed and nondiagnosed with myocardial infarction, have been used. These datas have been obtained by examining results of the biochemistry laboratory test, epicrisis reports and results of the angiography reports in consultancy with specialist physician. An intelligent decision support system has been developed by using gender, creatine kinase-MB (CK-MB), high sensitive troponin I, change of ST segment and change of ECG input datas. Conditions raising of CK-MB and troponin levels such as polymyositis(muscular inflammation), dermatomyositis(muscular inflammation), muscular dystrophy, patients who have had chronic renal failure, chronic hemodialysis, been made intramuscular injection in last 24 hours and had trauma or experienced skeletal injury in last 3 days etc. After datas were separated into two groups as train and test set, three different decision support system models have been developed by means of ANN, decision tree and SVM methods by

using datas of 205 patients in test set. While obtaining 79 % sensitivity, 83 % specificity values for SVM model, for decision tree model 91.7% sensitivity, 97.7% specificity values and for ANN model 98% sensitivity, 93% specificity values have been obtained. It has been seen that ANN model gave the most successful result among the three different models with 98% sensitivity.

Key Words: Artificial neural networks, decision tree, decision support system, heart attack, machine learning, support vector machine



3. GİRİŞ ve AMAÇ

Bilgi ve teknolojinin gelişmesiyle birlikte bilgisayar destekli çalışma alanları son yıllarda insan hayatını oldukça kolaylaştırmıştır. Askeriye, inşaat, taşımacılık, ekonomi ve sağlık gibi birçok alanda bilgisayarların yardımı ile daha verimli ve daha hızlı hizmet olanağı sağlanmıştır. Özellikle tıp alanında teknolojinin kullanılması hem kaliteli bir teşhis hem de daha hızlı tıbbi müdahale yapılabilmesini sağlamaktadır. Makine öğrenmesi ve veri madenciliği yöntemleri ile sağlık alanında hekimlere yardımcı olmak amacıyla birçok hastalığın sınıflandırılması, tahminlenmesi, risk hesaplanması gibi önemli çalışmalar yapılmaktadır.

BOH' lar (bulaşıcı olmayan hastalık) içerisinde kalp ve damar hastalıkları tüm ölüm nedenleri arasında ilk sırada yer almakta, özellikle iskemik (damar tıkanıklığı) kalp hastalıkları ve serebrovasküler hastalıklar ilk iki ölüm nedenini oluşturmaktadır. (1). 2012 yılında dünya genelinde meydana gelen 56 milyon ölümün 38 milyonu; BOH (bulaşıcı olmayan hastalıklar), özellikle kalp ve damar hastalıkları, kanser, kronik hava yolu hastalıkları nedeniyledir. 2012 yılında tüm dünyada BOH'lara bağlı ölümlerin yüzde 46,2'si (17,5 milyon) kalp ve damar hastalıkları nedeniyledir. Bu ölümlerin 7,4 milyonu kalp krizine (iskemik kalp hastalığı) 6,7 milyonu inmeye bağlıdır. BOH'lara bağlı 70 yaş altı ölümlerin yüzde 37'sinden kalp ve damar hastalıkları sorumludur. Kalp ve damar hastalıklarının küresel ölçekte uzun bir süre daha bir numaralı ölüm sebebi olmaya devam edeceği tahmin edilmektedir (1). Bu nedenle yapılan çalışmada kalp krizi (miyokard infarktüsü - MI) problemi ele alınmıştır.

Dangare ve arkadaşları tarafından 2012 yılında yapılan bir çalışmada veri madenciliği ve yapay sinir ağları yöntemleri kullanılarak kalp hastalığına yakalanma riskini tahmin eden bir model geliştirilmiştir. Açık kaynaklı bir veri tabanından alınan 573 veri üzerinde % 100'e yakın duyarlılıkta başarılı bir sistem elde edilmiştir (2). Doğan ve arkadaşları tarafından 2007 de yapılan bir başka çalışmada farklı biyokimya parametreleri kullanılarak veri madenciliği yöntemlerinden olan karar ağacı yöntemiyle kalp krizi teşhisi sistemi geliştirilmiştir. Hekimler tarafından 50 kalp krizi teşhisi alan ve 11 kalp krizi teşhisi almayan hasta verisi üzerinde doğru sınıflandırma gerçekleştirilmiştir (3).

Mair ve arkadaşları tarafından yapılan çalışmada biyokimyasal belirteçlerden bazıları ve EKG sonucu kullanılarak karar ağacı yöntemi ile %90 özgüllük ve %91 duyarlılık veren bir sistem geliştirilmiştir (4). Durairaj ve Revathi tarafından 2015 yılında yayınlanan bir çalışmada uluslararası veri tabanı UCI'den alınan 297 veri üzerinde % 96.30 duyarlı bir yapay sinir ağı geliştirilmiştir. Bu sayede kalp hastalıklarına yakalanma olasılığını %96.30 oranında doğru tahmin edebilen akıllı bir yardımcı sistem elde edilmiştir (5). Sunila ve arkadaşları tarafından 2012 yılında yayınlanan bir çalışmada uluslararası veri tabanı UCI'den alınan 720 veri kullanılarak iki farklı yapay sinir ağı modeli geliştirilmiş ve kalp damar hastalığı teşhis performansları kıyaslanmıştır (6) .

Bu tez çalışmasında makine öğrenmesi yöntemleri kullanılarak bir kalp krizi karar destek sistemi geliştirilmiştir. Geliştirilen bu sistem kullanılarak kısa sürede kalp krizi tanısı koymada hekimlere yardımcı olunabilir. Bununla birlikte, gelecek yıllarda yenilenen teknoloji ile taşınabilir tetkik cihazlarının da gelişmesiyle kalp krizi teşhisi hasta kliniğe varmadan koyulabilir ve uygun tedaviye hızlıca başlanabilir. Günümüzde acil servislere göğüs ağrısı şikayetiyle gelen hastalarda ilk istenen tetkiklerden biri EKG olup sonrada CK-MB ve troponinler gibi kalbe özgü bazı enzimlerin kandaki değerleri takip edilmektedir. CK-MB ve troponinler kalp krizi teşhisi koymada öncelikli ve önemli biyokimyasal belirteçlerdir. Bu değerlerin normalin üzerinde görülmesi durumunda kalp krizi düşünülür. Aynı şekilde kullanılacak bir diğer veri olan EKG yani kalbin elektriksel aktivitesi olup genellikle göğüs ağrısı şikâyeti ile acil servise gelen hastalarda kalp krizi tanısı koyabilme, düzenli veya düzensiz kalp ritim bozukluklarını (aritmiler) ortaya çıkarma vb. tanı koymada önemli rol oynayan bir diğer parametredir. Bu tez çalışmasında cinsiyet, CK-MB (kalp kreatin kinaz), HS-Troponin I (high sensitive troponin I) ve EKG giriş verileri kullanılarak akıllı bir kalp krizi karar destek sistemi geliştirilmiştir.

4. GENEL BİLGİLER

Kalp ve damar hastalıkları; koroner kalp hastalıkları, serebrovasküler hastalıklar, hipertansiyon, periferik arter hastalığı, romatizmal kalp hastalıkları, konjenital kalp hastalıkları, kalp yetmezliği ve kardiyomiyopatileri kapsamaktadır. Kalp ve damar hastalıklarının gelişiminde; tütün kullanımı, fiziksel hareketsizlik, obeziteye yol açabilen sağlıksız beslenme gibi olumsuz davranış tarzları yanında diyabet, hipertansiyon, dislipidemi gibi hastalıklar yer almaktadır. 2012 yılında tüm dünyada BOH'lara bağlı ölümlerin yüzde 46,2'si (17,5 milyon) kalp ve damar hastalıkları nedeniyledir. Türkiye İstatistik Kurumunun (TÜİK) ölüm verileri toplam ölümlerin içinde kalp hastalıklarının payının gittikçe artma eğiliminde olduğunu göstermektedir (1).

Tablo 1. Türkiye İstatistik Kurumu 2013-2014 yılı ölümverileri (1)


	2013 ⁽¹⁾		2014	
	Sayı	(%)	Sayı	(%)
Dolaşım sistemi hastalıkları	143.084	100,0	151.696	100,0
İskemik kalp hastalığı	55.753	39,0	60.040	39,6
Serebro-vasküler hastalık	35.977	25,1	37.403	24,7
Diğer kalp hastalığı	25.293	17,7	28.445	18,8
Hipertansif hastalıklar	18.337	12,8	17.572	11,6
Diğer	7.724	5,4	8.236	5,4

Tablo 1'e bakıldığında dolaşım sistemi hastalıkları ölüm nedeni olarak ilk sırada yer almaktadır ve bunlar arasında iskemik kalp hastalığı en büyük öneme sahiptir. İskemik kalp hastalığı koroner arterlerden geçen kan miktarının kalbin oksijen gereksinimini karşılayamayacak durumda olması sonucu ve çoğu kez arterlerin ateroskleroz ile daralması veya tıkanması sonucu ortaya çıkmaktadır. Bunu takiben oksijen yetersizliğinin derecesine göre angina pectoris ve kalp krizi görülebilmektedir.

4.1. Akut Koroner Sendrom

Acil servise göğüs ağrısı şikâyeti ile başvuran hastaların önemli bir kısmı Akut Koroner Sendrom tanısı almaktadır. Bu tanının olabildiğince erken konulması ve trombolitik tedavinin veya girişimsel işlemlerin zamanında yapılmasıyla mortalite (ölüm) ve morbidite (sağkalım) olumlu yönde etkilenmekte olup hastaların hastanede kalış süresi azalıp hastalığın prognozunda iyileşme sağlanmaktadır (7). Yapılan çalışmalar, acil servislere başvuran akut koroner sendrom tanısı alan hastaların %4-6'sının doğru teşhis konulamaması sonucu acil servislerden yanlışlıkla taburcu edildiğini göstermiştir (7).

Günümüzde, akut koroner sendromlar, başvuru elektrokardiyografileri (EKG) ve biyokimyasal belirteçlere dayanarak 3 guruba ayrılmıştır. Bunlar, EKG'sinde ST segment yükselmeli kalp krizi (STEMI) olan, EKG'sinde ST segment yükselmesi olmayan, ancak hasar belirteçlerinde yükselme ile ispat edilmiş kalp hasarı bulunanlar (NSTEMI) ve kararsız anjinalı (unstabil angina;UA) hastalardır.



Şekil 1. Akut koroner Sendrom (KM: kardiyak marker, STEMI: ST elevasyonlu miyokard infarktüsü, NSTEMI: ST elevasyonsuz miyokard infarktüsü, UAP: unstabil angina pectoris) (8, 9)

* JAPI'den uyarlanmıştır


Şekil 1'de görüldüğü gibi yapılan tez çalışmasında, miyokard infarktüsü ile ilgili olan STEMI ve NSTEMI hastaları ele alınmıştır. NSTEMI tanısı alan hastaların

görülme sıklığı STEMI tanısı alan hastaların görülme sıklığından daha fazladır. NSTEMI tanısı koymak da zordur ve bu nedenle prevalansını kestirmek kolay değildir. Geçen yıllar içinde STEMI sıklığı azalırken NSTEMI sıklığında bir artış söz konusu olduğu gözlemlenmektedir. STEMI hastane mortalitesi %7 iken NSTEMI hastane mortalitesi % 5 tir (10).

Kalp krizi kaynaklı ölümlerin % 50'si ilk bir saat içinde olmaktadır (11). Bu oran ilk 24 saat içinde % 80'e ulaşmaktadır (12). Erken dönemde tromboliz veya primer anjiyoplasti ile sağlanacak damar açıklığı, kalp krizi geçirmekte olan hastaların hızlı bir şekilde değerlendirilip tedavi sürecinin erken başlatılmasına yönelik stratejilerin geliştirilmesi önem taşımaktadır (12). Günümüzde açıkça bilinmektedir ki hastanede ilk müdahalesi yapılan hastaların %90'ı için çok erken dönemde tedaviye başlanması, önceki yıllarda düşünüldüğünden çok daha fazla önem taşımaktadır. Bu durumda MI'nün hastaneye gelmeden önceki ilk müdahalesinin önemi de artmaktadır.

4.1.1. Kalp Krizi (Miyokard İnfarktüsü)

Miyokard infarktüsü (MI), genellikle kalp krizi olarak adlandırılan bu tıbbi sorunun nedeni kalbin bir bölümünün kanlanmasının/oksijenlenmesinin bozulmasıdır. Yani kalbi besleyen damarların tıkanması sonucu kalbe yeterli kanın gidememesi durumudur (13).



Şekil 2. Kalp krizi oluşum süreci (14)

Kanlanamayan ya da diğer bir deyişle kan gitmediği için oksijen de gitmeyen kalp kası hücrelerinde hasar, kalp kası uzun süre oksijensiz kaldığında ise ölüm meydana gelir. Hem kadında hem de erkekte ölüm ile sonuçlanabilen bu sorun, hemen müdahale edilmesi gereken bir tıbbi acildir (13). MI'da semptomların başlangıcını izleyen ilk 6

saat içerisinde aspirin ve heparin ile birlikte kullanılan trombolitik ajanların, hastanedeki mortaliteyi %50'nin üzerinde azalttığı ve uzun süre sağ kalma oranını da önemli ölçüde arttırdığı bilinmektedir (11). Bu nedenle AKS tanısı alan hastaların uygun triajının ve MI'nün erken belirlenmesinin önemi daha da artmaktadır. MI hastalarının yaklaşık üçte birinde göğüs ağrısı atipik olduğundan ve hastaların yarıya yakınının EKG'si de nondiagnostik olduğundan bu hastalarda kardiyak belirteçlerin takibinin önemi artmaktadır (15). MI'ne bağlı ölümlerde hastaneye taşınma ve hastanın tanı alıp tedaviye başlama süresi büyük rol oynamaktadır.

4.1.2. Kalp Krizi Tanısı

Dünya Sağlık Örgütü (WHO)'ne göre MI teşhisi, göğüs ağrısı, EKG değişikliği ve kardiyak belirteçlerin yüksekliği kriterlerinden en az ikisinin varlığı ile konulmaktadır. (13). MI'lı hastalar bazen farklı varyasyonlar ile başvurabilirler. Bu sebeple hekim göğüs ağrısı ile gelen hastaların kardiyak belirteçlerine hem MI'yı dışlamak hem de teşhis için mutlaka bakmalıdır (9, 16, 17).

4.1.2.1. Göğüs ağrısı

Genellikle sol göğüs kemiği altında şiddetli ezici karakterde, sol kola yayılan göğüs ağrısı ve birlikte ölüm korkusu, göğüste rahatsızlık hissi ile ortaya çıkan göğüs ağrısıdır (18). Göğüsteki rahatsızlık hissi boyun, çene, sırt, omuz, sağ kol ve epigastrik (mide çukuru) bölgeye yansıyabilir. Göğüs ağrısı olmaksızın bu bölgelerden birinde ağrı olması muhtemeldir. MI özellikle ameliyat sonrası dönemdeki hastalarda, yaşlılarda, hipotansiyon, diyabet ve semptomlu kalp yetersizliği olan hastalarda göğüs ağrısı olamadan da görülebilir. Nitratlar ile geçmez ve hafiflemez. Göğüs ağrısı sıklıkla terleme, bulantı, halsizlik, korku ve ölüm hissi gibi belirtiler ile birlikte olur. (18, 19).

4.1.2.2. Fizik muayene

Genelde fizik muayene MI tanısına ek katkı sağlamaz. Çünkü bazı vakalarda fizik muayene tamamen normal olabilir (18). Ancak MI'nü taklit edebilecek diğer hastalıkları ekarte etmek, risk sınıflaması yapmak, gelişen kalp yetersizliği tanısını koymak gibi farklı amaçlar için fizik muayene yapılması önemlidir (19).

4.1.2.3. Laboratuvar bulguları-testleri

Kreatinin kinaz

CK kas hücrelerinde sentez edilen bir enzimdir. İzoenzimleri M ve B subünitelerinin birleşmesi ile meydana gelmektedir. CK-MM, iskelet kasında; CK-BB, beyinde; CK-MB, kalp kasında bulunur. Kalpte büyük konsantrasyonda ayrıca küçük miktarlarda iskelet kasında, dilde, ince bağırsakta ve diyafragmada bulunmaktadır. CK-MB markerleri MI başlamasından 3 saat içerisinde serumda görülür. 12-24 saatte tepe düzeyine ulaşır. Serumda aktivitesi 1-3 gün devam etmektedir (18). Spesifitesi oldukça yüksektir. Bu yüzden son yıllarda CK-MB ölçümü oldukça fazla önem taşımaktadır. CK-MB'yi yükselten MI dışındaki sebepler: Prostat veya uterus cerrahisi, ince bağırsak, dil, diyafram travması, ağır egzersiz, kardiyak cerrahi, miyokardit, kronik renal yetmezlik (9, 20).

Troponinler

Troponin T ve troponin I testleri, yüksek hassasiyetleri, yatak başı hızlı uygulanabilme ve yorumlanabilme özellikleri ve neredeyse tüm dünyada yaygın kullanımı olması nedeniyle kararsız anjina ve NSTEMI tanı ve tedavi yönteminde oldukça yararlıdır (11). Kan serumunda tespit edilebilir konsantrasyona ulaşma zamanı yaklaşık 3-6 saattir. CK'nın aksine ilk saatlerde kullanımları sınırlıdır (9, 18). Bunun yanı sıra sensitivite ve spesifiteleri yüksek olması nedeniyle günümüzde göğüs ağrısıyla bir kliniğe başvuran hastalara rutin bakılan ilk ve önemli enzimlerdendir.


Miyogloblin

Hasarlanan kas hücreleri hızla bu proteini salmaktadır ve tepe düzeyi 1-4 saatte meydana gelmektedir. MI'nin teşhis edilmesine yardımcı olmaktadır. Ancak kardiyak spesifitesi düşüktür, dolayısıyla klinikte kullanımı sınırlıdır. Miyogloblin 2-6 saatlik zaman aralığında ölçüldüğünde sonuç negatif ise MI'yi kolaylıkla dışlayabilmektedir (9, 21).

Elektrokardiyografi (EKG)

EKG (elektrokardiyografi) yani kalbin elektriksel aktivitesi olup genellikle göğüs ağrısı şikâyeti ile gelen hastalarda kalp krizi tanısını koyabilme, düzenli veya düzensiz kalp ritim bozukluklarını (aritmler) ortaya çıkarmada önemli bir rol oynayan ilk

parametredir. MI teşhisinde uygulanması basit ve kullanışlı olan tek yöntemdir. Bundan dolayı MI sınıflandırması EKG bulgularına göre yapılmaktadır. ST elevasyonlu (STEMI) ve Non ST elevasyonlu (NSTEMI) olmak üzere iki guruba ayrılırlar. Akut miyokard infarktüsü ve iskeminin teşhis edilmesinde erken dönemde seri çekilen 12 derivasyonlu-EKG ‘nin tanısallık değeri yüksektir (21). MCPS’de (çok merkezli göğüs ağrısı çalışması) MI olgularının %2’sinde EKG normal bulunmuştur. MI teşhisi için iki veya daha fazla komşu derivasyonda ≥ 1 mm ST elevasyonu görülmesi gerekmektedir ve sıklıkla bunların karşı tarafındaki derivasyonlarda ise ST depresyonu görülmektedir (9, 21).



Şekil 3. EKG dalgaları gösterimi (22)

4.2. Kalp Damar Hastalıklarını Tetikleyen Risk Faktörleri

4.2.1. Obezite

Obezite gelişmiş ülkelerin ve gelişmekte olan ülkelerin giderek artan önemli bir sağlık problemidir. Fazla kilolu olma ve obezite her yıl yaklaşık 3,4 milyon ölüme sebep olmaktadır. Prospektif yapılan çalışmalar kilolu olma hali ve obezite ile kalp ve damar hastalıklarına bağlı morbidite ve mortalite arasında ilişki olduğunu göstermiştir. Obezitenin yüksek kan basıncı, glukoz intoleransı, tip 2 diyabet ve dislipidemi gibi kalp

ve damar hastalıkları risk faktörleri ile kuvvetli ilişkisi vardır. Koroner kalp hastalığı, iskemik inme, tip 2 diyabet riski artan beden kütle indeksi ile arttığı bilinmektedir (1).

4.2.2. Hipertansiyon

2010 yılında dünya genelinde yıllık 9,4 milyon ölüm ve hastalık yükünün yüzde 7'sinden HT sorumlu tutulmaktadır. Yüksek kan basıncı, koroner kalp hastalığı ve serebrovasküler (beyin damarları) hastalık için büyük risk faktörüdür. Kan basıncı seviyesinin, inme ve koroner kalp hastalığı ile anlamlı ve ilerleyici ilişkisi olduğu kabul edilmektedir. Aynı yaş grubunda 115/75 mmHg'dan itibaren kan basıncındaki her 20/10 mmHg'lık artış kalp ve damar hastalıkları riskini iki katına çıkarmaktadır. Koroner kalp hastalığı ve serebrovasküler hastalığa ek olarak yüksek kan basıncı kalp yetmezliği, renal yetmezlik, periferik damar hastalığı, retinal kan damarlarında bozulma ve görme kaybına yol açtığı bilinmektedir (1).

4.2.3. Diyabet

Diyabetli kişilerde ölümün yüzde 60'nın nedeni kalp ve damar hastalıklarıdır. Tip 1 veya tip 2 diyabetli kişilerde kalp ve damar hastalıkları görülme sıklığı 2-3 kat daha artmaktadır. Kadınlarda risk daha yüksektir. Diyabetli kişilerde kalp ve damar hastalıklarından sonra hastalığın ilerleme süreci diyabetli olmayanlara göre daha kötüdür. Kalp ve damar hastalıkları riski yüksek glukoz değerleri ile artar. Ayrıca anormal glukoz regülasyonu santral obezite, yüksek kan basıncı, düşük HDL kolesterol, yüksek trigliserid seviyeleri gibi bilinen kalp ve damar hastalıkları risk faktörleri ile birlikte olma eğiliminde olduğu düşünülmektedir (1).

4.2.4. Yüksek Kan Kolesterolü

Yüksek kan kolesterolü kalp krizi riskini artırır. Genel olarak iskemik kalp hastalıklarının 1/3'ü yüksek kolesterolle ilişkilidir. Yüksek serum kolesterolünü düşürmenin kalp hastalığı riskini azaltmasının yanı sıra yapılan çalışmalarda 40 yaşındaki bir erkekte kan kolesterolündeki yüzde 10'luk azalmanın 5 yıl içinde kalp hastalığı riskini yüzde 50 azalttığı tespit edilmiştir (1).

4.2.5. Cinsiyet

Kadınlarda kalp ve damar hastalıkları hakkında birçok yanlış bilinen kanı vardır. Kadınlar da erkekler kadar kalp ve damar hastalıklarına yakalanmaktadır. Kadınlarda

erkeklere göre kalp damar hastalığı 7-10 yıl daha geç gelişmektedir. Her yıl 3.3 milyon kadın kalp krizinden ölmektedir (1). MI sonrası ölüm oranı kadınlarda erkeklere göre daha yüksektir (23).

4.2.6. Yaş

Yaş güçlü bir kalp ve damar hastalıkları risk faktörüdür. Düşük ve orta gelir düzeyindeki ülkelerde artan kalp ve damar hastalıkları yükü nüfusun yaşlanması ile ilişkili olduğu düşünülmektedir (1).

4.2.7. Tütün Kullanımı

Tütün kullanımının kalp ve damar hastalıklarının %10'nuna neden olduğu tahmin edilmektedir. Yapılan çalışmalarla sigarayı bırakmanın koroner kalp hastalığına bağlı ölümleri azaltıcı etkisi gösterilmiştir (1).

4.2.8. Alkol Kullanımı

Alkol tüketimi ile kalp ve damar hastalıkları riski arasında ilişki olduğu bilinmektedir. Ayrıca alkol kullanımı kalp kasında hasara yol açabilme, kardiyak aritmiye sebep olma ve inme riskini artırma gibi durumlara sebep olabilir (1).


4.2.9. Aile Öyküsü

Eğer baba ya da erkek kardeş 55 yaşından önce; anne ya da kız kardeş 65 yaşından önce kalp krizi geçirmiş, koroner kalp hastalığı tanısı almış ya da aniden ölmüş ise ailede kalp damar hastalığı öyküsü var demektir. Aile öyküsünün varlığı risk faktörlerinden biri olarak görülmektedir (24) .

4.3. Makine Öğrenmesi Yaklaşımı

İlk olarak 1950'li yıllarda insan gibi düşünen ve insan gibi davranan makinelerin yapılması ile önemli bir adım atılmış, yapay zekâ (artificial intelligence) bilimi ile insan gücünün ötesinde insan beyninin yerini alabilecek makinelerin üretilmesi amaçlanmıştır (25). İnsan beyninin doğuştan öğrenebilme yeteneği vardır. Fakat makineler için aynı durum söz konusu değildir. Bir makinenin öğrenebilmesi için gerekli şartların açıkça belli olması gereklidir. Öğrenen varlığın makine ya da insan olmasına bakılmaksızın, ana öğrenme süreci ikisinde de benzerlik göstermektedir. Bu öğrenme süreci birbiriyle ilişkili dört öğeden oluşur:

- **Depolama:** Gözlemlerden, hafızadan ve çağrışımlardan faydalanır.
- **Soyutlama:** Depolanmış veriyi daha kapsamlı simgelere ve kavramlara dönüştürür.
- **Genelleştirme:** Bilgi ve çıkarımları oluşturmak için soyutlanmış veriyi kullanır.
- **Değerlendirme:** Öğrenilen bilginin kullanılabilirliğini ölçmek ve olası gelişmeleri haber vermek için bir geribildirim mekanizması kullanır (26).



Şekil 4. Makine öğrenmesi süreci (27)

Makineler veriden öğrenmeyi sağlayan bilgisayar yazılımları olup bu yazılımların temelinde insan düşüncesiyle ortaya çıkarılan algoritmalara dayanmaktadır.

Makine öğrenmesi adı altında ele alınan teknikler veriden öğrenmeye dayalı teknikler olup çıktıların sınıflanması veya kümelenmesini sağlayabilecek algoritmaları meydana getirir. Makine öğrenmesini sağlayan aslında kullanılan algoritmalar (25). Makine öğrenmesi algoritmaları amaçlarına göre kategorilere bölünür (26). Ele alınan veri setinde çıktı değerleri biliniyorsa danışmanlı/eğitmenli öğrenme (Supervised learning), bilinmiyorsa danışmansız/eğitmensiz öğrenme (Unsupervised learning) algoritmaları kullanılmaktadır (25).

4.3.1. Danışmanlı Öğrenme

Danışmanlı öğrenmede amaç sınıflandırmayı sağlayabilecek bir model oluşturmaktır. Model aynı problemi çözmede, yeni veri ile tahminler yapabilmek için kullanılabilir. Bu öğrenmede elde edilecek sonuç, tahmini istenen çıktı değerini ya da etiketlenmiş değer biliniyor durumudur. Diğer bir deyişle girdi değerleri bir danışman (veya eğitmen) tarafından çıktı değerlerine etiketlenir. Bu koşullarda danışman desteğinde eğitilen veri seti çıktı değerlerinin tahmin edildiği bir model

oluşur. Bu model, tahmin edilen çıktı değerleri ile bilinen çıktı değerleri arasındaki farkın en aza indirildiği bir modeldir (25).

4.3.2. Danışmansız Öğrenme


Danışmansız öğrenmede birbirine yakın örnekler benzerliklerine göre kümelenmekte veya ilişkileri dikkate alınarak birliktelik analizleri ile model oluşturmaya gerek kalmadan çözümler bulunmaktadır. Çıktı değerinin olmadığı veya bilinmediği durumlarda sadece girdi değerlerinden hareket edilerek girdilerin gruplanması, diğer bir deyişle kümelenmesi (clustering) sağlanmaktadır (25).

Yapılan tez çalışmasında kalp krizi karar destek sisteminin geliştirilmesinde danışmanlı öğrenme yaklaşımlarından YSA, DVM ve karar ağacı yöntemleri kullanılmıştır.

5. GEREÇ ve YÖNTEMLER

5.1. Destek Vektör Makineleri

Genelde makine öğrenmesi yöntemi denilen karar destek sistemleri, yapılacak işlemlerin açıkça tanımlanamadığı durumlarda, verilen girdilere karşılık gelen çıktının ne olduğunu, eldeki eski bilgi ve tecrübeler yardımı ile tahmin edilmesi işlemidir. Destek vektör makineleri (DVM) güçlü istatistiksel teoriler üzerine inşa edilmiş bir makine öğrenmesi yöntemidir (28). DVM, istatistiksel öğrenme teorisine dayalı bir kontrollü sınıflandırma algoritmasıdır (29). DVM'nin sahip olduğu matematiksel algoritmalar başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir. DVM'nin çalışma prensibi iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonunun tahmin edilmesi, başka bir ifadeyle iki sınıfı birbirinden en uygun şekilde ayırabilen hiper-düzlemin tanımlanması esasına dayanmaktadır (29).



Şekil 5. Destek vektör makineleri çalışma prensibi (30)

Geleneksel makine öğrenmesi yöntemlerinde çok sayıda eğitim verisine sahip olma isteği, düşük yakınsama oranı, yerel minimuma takılma ve fazla uyum/eksik uyum (overfitting/underfitting) problemleriyle karşılaşmaktadır. DVM, yapısal risk minimizasyonu temelinde çalışarak bu problemlerin üstesinden gelmiştir. DVM yüksek boyutlu fakat az sayıda veri içeren uygulamalarda da başarılıdır. Bu özelliklerinden dolayı veri madenciliği, karar destek sistemleri, müşterilerin dolandırıcılık tespiti ve görüntü sınıflandırma gibi birçok uygulama alanında kullanılmıştır (29). Avantajları ve dezavantajları aşağıdaki tabloda verilmiştir.

Tablo 2. DVM avantajları ve dezavantajları (26)

Avantajlar	Dezavantajlar
• Numerik tahmin problemleri ve sınıflandırma için kullanılabilir. • Gürültülü verilerden çok etkilenmez ve uyum problemi yaşamaz. • Özellikle iyi desteklenmiş DVM algoritmalarından dolayı kullanımı YSA'dan daha kolay olabilir. • Yüksek doğruluk oranı ve profilinden dolayı veri madenciliği yarışmalarında popülaritesi artmaktadır.	• En iyi modeli bulmak için kernel fonksiyonları ve parametreler ile çeşitli kombinasyonlar yapmak gerektirir. • Eğer data çok fazla özellik ve örneğe sahipse eğitimi yavaşlayabilir. • Kompleks kara kutu yapısından dolayı yorumlanması imkansız değildir ama zordur.

DVM eğitim esnasında gözlenmemiş yeni verileri de sonsuz olarak sınıflandırabilmektedir ve bu durum DVM'nin genelleştirebilme yeteneğini göstermektedir. DVM literatüründe tahmin edici veya bağımsız (predictor) değişkene doğal nitelik(attribute), optimum hiper düzlemi belirlemek için kullanılan dönüştürülmüş doğal niteliğe belirleyici nitelik(feature) ve bir deneği (gözlemi) tanımlayan belirleyici nitelik setine ise vektör denilmektedir. DVM'nin temelini, verilerin bir düzlem veya hiper düzlem ile ayrılarak sınıflandırılması işlemi oluşturmaktadır. Yani iki sınıfa ait verileri ayırabilecek en uygun düzlemi veya hiper düzlemi belirlemektir. Doğrusal olarak ayrılabilen verileri, ait oldukları boyutta bir düzlem ile ayırabilmek mümkünken doğrusal olarak ayrılamayan verilerin ait oldukları boyuttan daha yüksek boyutlu bir uzaya taşınarak burada bir hiper düzlem ile ayırmak mümkün olacaktır (31).


5.1.1. Doğrusal Ayrılabilen Veriler için DVM

Destek vektör makineleri ile sınıflandırmada genellikle $\{-1,+1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. Söz konusu karar fonksiyonu

kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper-düzlem bulunur. İki sınıflı verileri birbirinden ayırabilen bir çok hiper düzlem çizilebilir. Ancak DVM'nin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkaran hiper-düzlemi bulabilmektir. Sınırı maksimuma çıkararak en uygun ayrımı yapan hiper-düzleme optimum hiper düzlem ve sınır genişliğine sınırlandıran noktalar ise destek vektörleri olarak adlandırılır (29).

5.1.2. Doğrusal Ayrılamayan Veriler için DVM

DVM'ler doğrusal olmayan problemlerle karşılaştığında orijinal verilerden sınıflandırma özelliklerini çıkarmak için, doğrusal olmayan haritalama (mapping) yaparak verilerin boyutlu orijinal girdi uzayından daha yüksek boyuta sahip belirleyici nitelik (feature) uzayına taşır. DVM daha sonra, belirleyici nitelik uzayında maksimum marjini bulmak için doğrusal sınıflandırma kuralını öğrenir. Sınıflandırma kuralı, belirleyici nitelik uzayında doğrusal olması gerçeğine karşın orijinal girdi uzayına izdüşüm yapıldığında doğrusal değildir. Doğrusal olmayan DVM, verilerin taşındığı bu yeni boyutta doğrusal DVM gibi çalışarak verileri ayıracak optimum hiper düzlemi arar (31).



Şekil 6. Doğrusal ayrılamayan verilerle DVM (32)

Destek vektör makineleri matematiksel olarak $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ şeklinde ifade edilen bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayırılmasına imkan sağlamaktadır.

Literatürde kernel fonksiyonu olarak en sık kullanılan polinom, radyal tabanlı fonksiyon, Pearson VII (PUK) fonksiyonu ve normalleştirilmiş polinom kernelleridir.

Kernel fonksiyonları karşılaştırıldığında polinom ve radyal tabanlı kerneller daha sade ve anlaşılabilir (29).

Linear kernel: Veriyi asla dönüştürmez. Veri setindeki özelliklerin çarpımları olarak ifade edilebilir (26).

$$K(\vec{x}_i, \vec{x}_j) = \vec{x}_i * \vec{x}_j \quad (5.1)$$

Polynomial kernel: Verinin basitçe linear olmayan dönüşümünü toplar (26).

$$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i * \vec{x}_j + 1)^d \quad (5.2)$$

Sigmoid kernel: Yapay sinir ağına oldukça paralel olan bir sigmoid fonksiyon kullanarak modeli oluşturur. Yunan harfleri olan kappa ve delta kernel parametreleri olarak kullanılır (26).

$$K(\vec{x}_i, \vec{x}_j) = \tanh(\kappa \vec{x}_i * \vec{x}_j - \delta) \quad (5.3)$$

Radial basis kernel: Radyal tabanlı yapay sinir ağı ile benzerdir. Çeşitli tipteki datalarda iyi sonuç verir (26).

$$K(\vec{x}_i, \vec{x}_j) = e^{-\frac{\|\vec{x}_i - \vec{x}_j\|^2}{2\sigma^2}} \quad (5.4)$$


5.2. Karar Ağaçları

Karar ağaçları, veri madenciliğinde kuruluşlarının ucuz olması, yorumlanmalarının kolay olması, veri tabanı sistemleri ile kolayca entegre edilebilmeleri ve güvenilirliklerinin iyi olması nedenleri ile sınıflama modelleri içerisinde en yaygın kullanıma sahip tekniktir. Ağaç yapısı ile kolay anlaşılabilen kurallar yaratabilen, bilgi teknolojileri işlemleri ile kolay entegre olabilen en popüler sınıflama tekniğidir (33). Karar ağaçları, sınıflandırma ve tahmin için sıkça kullanılan bir veri madenciliği yaklaşımıdır. Sinir ağları gibi diğer metodolojilerin de sınıflandırma için kullanılabilmesine rağmen, karar ağaçları, kolay yorumu ve anlaşılabilirliği açısından karar vericiler için avantaj sağlamaktadır (34).

Karar ağaçları adında anlaşılacağı üzere kararın verilebilmesi için ağaç biçiminde bir yapı oluşturan tahmin edici bir tekniktir (25, 35). Karar ağaçları akış şemalarına

benzeyen yapılardır. Her bir nitelik bir düğüm tarafından temsil edilir. Dallar ve yapraklar ağaç yapısının elemanlarıdır.

En son yapı ”yaprak”, en üst yapı “kök” ve bunların arasında kalan yapı ise “dal” olarak adlandırılır. Karar ağaçlarında karar düğümleri ve yaprak düğümleri bulunur. Karar düğümleri (decision nodes) veri setinde karar vermek, sınıflandırma yapmak ya da tahmin etmek için kullanılan niteliklerdir olup, iki yada daha fazla dala (branch) ayrılabilirler. Yaprak düğümleri (leaf nodes) ise kararları tutmaktadırlar. Ağacın en tepesinde bulunan düğüm, kök düğümdür (root node) ve bir karara ulaşabilmek için ağacın kökünden yaprak düğümlere kadar belirli bir yol (path) izlenir (25).



Şekil 7. Hava tahmini karar ağacı modeli (36)

Karar ağacı tekniğini kullanarak verinin sınıflanması, öğrenme ve sınıflama olmak üzere iki basamaklı bir işlemdir. Öğrenme basamağında önceden bilinen bir eğitim verisi, model oluşturmak amacıyla sınıflama algoritması tarafından analiz edilir. Öğrenilen model, sınıflama kuralları veya karar ağacı olarak gösterilir. Sınıflama basamağında ise test verisi, sınıflama kurallarının veya karar ağacının doğruluğunu belirlemek amacıyla kullanılır.

Eğer doğruluk kabul edilebilir oranda ise kurallar, yeni verilerin sınıflanması amacıyla kullanılır. Eğitim verisindeki hangi alanların hangi sırada kullanılarak ağacın oluşturulacağı belirlenmelidir (34).

Karar ağaçlarında kullanılan birçok algoritma mevcuttur. ID3, C4.5, C5.0, CART, CHAID ve QUEST bunlara örnek olarak gösterilebilir.

C4.5 ve C5.0 Algoritmaları: En yaygın kullanılan karar ağacı algoritması Quinlan'ın ID3 algoritmasının geliştirilmiş hali olan C4.5 algoritmasıdır. C5.0 algoritması ise C4.5'in geliştirilmiş hali olup özellikle büyük veri setleri için kullanılmaktadır (34).

CART Algoritması :Hem sayısal hem de nominal veri türlerini, girdi ve kestirimsel değişken olarak kabul edebilen CART algoritması, sınıflandırma ve regresyon problemlerinde bir çözüm olarak kullanılabilir. CART karar ağacı, ikili olarak özyinelemeli biçimde bölünen bir yapıya sahiptir (34).

CHAID Algoritması: CART'ın dışında en çok kullanılan karar ağacı algoritmalarından biri de CHAID'dır. CHAID optimal bölünmelerin tespiti için ki-kare istatistiğini kullanan bir yöntemdir. CHAID, bölümlendirme amaçlı kullanılan etkili bir istatistiksel tekniktir (34).

QUEST Algoritması: İkili karar ağacı yapısı kullanan bir sınıflandırma algoritmasıdır. İkili ağaç kullanılmasının sebebi, ikili ağaçlarda budama ve doğrudan durma kuralı gibi tekniklerin kullanılabilmesidir (34).


Tablo 3: Karar ağaçları avantajları ve dezavantajları (37, 38)

Avantajlar	Dezavantajlar
• Karar ağaçları veri madenciliğinde kuruluşlarının basit olması nedeniyle çok tercih edilmektedir. • Yorumlanmaları kolaydır. • Veri tabanı sistemleri ile kolayca entegre edilebilirler. • Güvenilirlikleri iyidir.	• Eğer az sayıda özellik var ise iyi performans gösterirler fakat daha kompleks etkileşimler var ise daha düşük performans gösterirler. • Kök bölümüne yakın bir ayırmada küçük bir değişiklik olursa ağacın geri kalan yapısı da tamamen değişir. • Yol boyunca çok sayıda özellik test edilirse parçalanma problemleri ortaya çıkabilir. • Eksik değerler ile başa çıkmak avantaj olarak düşünülse de, aslında bu değerlerle başa çıkmak için harcanan enerji eksiklik olarak düşünülebilir.

5.3. Yapay Sinir Ağları


Yapay sinir ağları (YSA), yapay zekâ biliminin altında araştırmacıların çok yoğun ilgi gösterdikleri bir yöntemdir. Bilgisayarların öğrenmesine yönelik çalışmaları kapsamaktadır. Bulundukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan bu hesaplama yönteminin hayatın hemen hemen her alanında başarılı uygulamalarını görmek mümkündür. Özellikle sınıflandırma, örüntü tanıma, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmalarında yapay sinir ağları en güçlü teknikler arasında sayılabilir (39). YSA, hesaplama ve bilgi işleme bakımından güçlüdür. Bu gücünü paralel dağılmış yapısından öğrenebilme ve genelleme yeteneğinden alır. Yani YSA'lar karmaşık problemleri de çözebilme yeteneğine sahiptirler (40).

Yapay Sinir ağıları insan beyninin em temel özelliği olan öğrenme fonksiyonunu gerçekleştiren bilgisayar sistemleridir. Bu ağılar birbirine bağlı proses elemanlarından (yapay sinir hücrelerinden) oluşur. Her bağlantının bir ağırlık değeri vardır. Yapay sinir ağının sahip olduğu bilgi bu ağırlık değerlerinde saklı olup ağa yayılmıştır (40). Yapay sinir ağıları biyolojik sinir sisteminden etkilenerek geliştirilmiştir.



Şekil 8. Biyolojik Sinir Hücresi Yapısı (41)

Biyolojik sinir hücreleri birbirleri ile synapsler vasıtası ile iletişim kurarlar. Bir sinir hücresi işlediği bilgileri axon'ları yolu ile diğer hücelere gönderirler. Benzer şekilde yapay sinir hücreleri dışarıdan gelen bilgileri bir toplama fonksiyonu ile toplar ve aktivasyon fonksiyonundan geçirerek çıktıyı üretip ağı bağlantılarının üzerinden diğer hücelere (proses elemanlarına) gönderir.



Şekil 9. Yapay sinir hücresinin yapısı (42)

Şekil 9’da görüldüğü üzere her bir x_i , hücreye girişi (dendriti) temsil etmektedir. Her bir girişin, kendisine has olmak üzere bir ağırlığı vardır (w_i). Her x_i girişi, kendi ağırlığı ile çarpılarak, çekirdeğe doğru yönlendirilir ve bu girişlerin çıktıları çekirdekte toplanır. (y) yapay sinir hücresinin çıkış değeridir. YSA’da her bir girdi (x_i) ve çıktıya (y) göre, girişlerin ağırlıkları (w_i) değiştirilir. Bu ağırlıkların değiştirilmesiyle hücrenin öğrenmesi gerçekleştirilir. Çekirdekte gerçekleşen çıkış değerinin hesaplanmasını fonksiyonel olarak gösteren matematiksel ifade şu şekildedir:

$$y(x) = f(\sum_{i=1}^n w_i x_i) \quad (5.5)$$

Aktivasyon fonksiyonları, YSA'ların eğitiminde ciddi öneme sahiptir. Özellikle yayımlı öğrenmelerde bu fonksiyonlarının türevi alınabilen sürekli fonksiyonlardan olması tercih edilmektedir. Bazı aktivasyon fonksiyonları, negatif ve pozitif aralıklarda çalışırken bazıları ise sadece belli aralıklarda pozitif değerler üretmektedir (43). Aktivasyon fonksiyonları, doğrusal ve doğrusal olmayan biçimlerde. Step ve signum fonksiyonları genellikle örüntü tanıma ve sınıflandırmada kullanılırken sigmoid fonksiyonu geri yayımlı ağlarda kullanılmaktadır. Doğrusal aktivasyon fonksiyonu ise genellikle lineer yakınlıştırmalarda (linear approximation) kullanılmakta ve çıkışı ağırlandırılmış nöron girişleriyle denk tutmaktadır (44). Sigmoid Aktivasyon Fonksiyonu; türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeni ile uygulamada en çok kullanılan aktivasyon fonksiyonudur.

Yapay sinir ağı modelleri bir ağı öğrenmesi gereken giriş-çıkış bilgilerine ve sentetik sinirler arası ilişkilerle ifade edilen mimarilerine göre farklılıklar göstermektedir. Öğrenme biçimine göre YSA’lar danışmalı (supervised) ve danışmansız (unsupervised) olmak üzere ikiye ayrılır. Danışmanlı öğrenmede ağa giriş-çıkış vektörleri şeklinde ayrıntılı şekilde eğitim örnekleri verilmektedir. Danışmansız öğrenmede ise ağı giriş bilgileri verilerek problemin çözümü ağdan istenmektedir (44).

Mimarisine göre ise YSA belirli (deterministic) ve belirsiz (stochastic) olarak ikiye guruba ayrılır. Ayrıca, sinir ağlarının işaretin akış yönüne bağlı olarak ileri beslemeli (feedforward) ve geri beslemeli (feedback) türleri de bulunmaktadır (44). YSA’lar yapılarına göre farklılık arz etmektedir. YSA’lar tek katmanlı ileri beslemeli, çok katmanlı ileri beslemeli ve döngülü yapay sinir ağları olmak üzere üçe ayrılmaktadır.

Tek katmanlı ileri beslemeli yapay sinir ağının bir adet giriş katmanı ve bir adet çıkış katmanı bulunmaktadır. Bu YSA tipinde verilen girdi giriş katmanından çıkış katmanına doğru ilerler. Bu durum ağın “ileri beslemeli ağ” olarak nitelendirilmesini sağlar. Çok Katmanlı İleri Beslemeli YSA’lar ise bir veya daha fazla gizli katman bulundurmaktadır. Burada gizli katmanların YSA’da kullanılmasıyla, giriş ve çıkış katmanları arasında gerekli bir takım işlemler yapılmaktadır. Çok katmanlı yapılarda, N adet katmana sahip bir YSA’da N’nci katmanın çıkış sinyalleri N+1’nci katmana iletilerek bu katmanda giriş sinyalleri olarak kullanılmaktadır. Eğer her katmanda bulunan nöronlar bir sonraki katmanın tüm nöronlarına bağlı ise bu tip ağa “tam bağlantılı ağ” adı verilmektedir. Eğer bu bağlantılardan bazıları gerçekleştirilmemişse kısmi bağlantılı ağ adı verilir (43).

Günümüzde belirli amaçlarla ve değişik alanlarda kullanılmaya uygun birçok yapay sinir ağı modeli (Perceptron, Adaline, MLP, LVQ, Hopfield, Recurrent, SOM, ART vb.) geliştirilmiştir. Bu ağ yapıları içerisinde en yaygın kullanım alanı bulan ve çalışmamızda da kullanılan çok katmanlı ileri beslemeli yapay sinir ağlarıdır. (Multiple Layer Perceptron-MLP) (45).

Yapay sinir ağları, kullanılan hücre modeli, bu hücrelerin ağ yapısında bir arada bağlanma şekli (ağ topolojisi), ağırlıkların ayarlanması için öğrenme kuralının belirlenmesi ve hatırlama ile karakterize edilir. Ağ eğitimi için en yaygın kullanılan modeli, ileri beslemeli–geri yayılım algoritmasıdır. Geri yayılım algoritması, hataları geriye doğru (çıkıştan girişe) azaltmaya çalışmasından dolayı “geri yayılım” ismini almıştır. Geri yayımlı öğrenme kuralı, ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Geri yayımlı bir ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte; problemin özelliklerine göre gizli katman sayısını artırabilmek mümkündür (45).


5.3.1. Çok Katmanlı Yapay Sinir Ağı (MLP)

MLP ağlarında nöronlar katmanlar şeklinde organize edilmiştir (45).

- **Girdi katmanı:** Dış dünyadan bilgileri alır. Bu katmanda herhangi bir bilgi işleme olmaz.
- **Ara katmanlar:** Girdi katmanından gelen bilgileri işlerler. Bir adet ara katman ile birçok problemi çözmek mümkündür. Eğer ağın öğrenmesi

istenilen problemin girdi/çıkıtı arasındaki ilişkisi doğrusal olmaz ve karmaşıklık artarsa birden fazla sayıda ara katmanda kullanılabilir.

- **Çıkıt katmanı:** Ara katmandan gelen bilgileri işleyerek ağa girdi katmanından sunulan girdi için ağın ürettiği çıktıyı bulur. Bu çıktı dış dünyaya iletilir (39).



Şekil 10. Çok katmanlı yapay sinir ağı (46)

Teknik olarak bir YSA'nın en temel görevi, örnek veri setindeki yapıyı öğrenerek istenilen görevi yerine getirecek şekilde genelleştirmeler yapmasıdır. Bunun yapılabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapılabilecek yeteneğe kavuşturulur. YSA'nın öğrenmesi, işlem elemanlarının sahip olduğu ağırlıkların seçilen eğitim algoritmalarıyla değiştirilmesi ile yapılmaktadır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı MLP ağlarının eğitiminde geri yayılım (backpropagation) algoritması kullanılmaktadır.

Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayılım algoritması danışmanlı öğrenme yapısına sahip ve birçok uygulamada kullanılmış en yaygın öğrenme algoritmasıdır (45).

Tablo 4. YSA kullanım alanları (40, 44)

YSA kullanım alanları	
Sigortacılık	Ürün optimizasyonu, uygulama politikası geliştirme vs. Üretim: Üretim işlem kontrolü, ürün dizaynı, makina yıpranmalarının tespiti, dayanıklılık analizi, kalite kontrolü, iş çizelgeleri hazırlanması vs.
Robotik	Yörünge kontrol, forklift robotları, görsel sistemler, uzaktan kumandalı sistemler, optimum rota belirleme vs.
Dil	Sözcük tanıma, yazı ve konuşma çevrimi, dil tercüme vs.
Telekomünikasyon	Görüntü ve data karşılaştırma, filtreleme, eko ve gürültü söndürülmesi, ses ve görüntü işleme, trafik yoğunluğunun kontrolü ve anahtarlama vs.
Güvenlik	Parmak izi tanıma, kredi kartı hileleri saptama, retina tarama, yüz eşleştirme vs.
Sağlık	Meme kanseri erken teşhis ve tedavisi, EEG, EKG, MR, kalite artırımı, ilaç etkileri analizi, kan analizi sınıflandırma, kalp krizi erken teşhis ve tedavisi vs.

Tablo 5. YSA avantajları ve dezavantajları (40, 44)

Avantajlar	Dezavantajlar
• YSA, makine öğrenmesi gerçekleştirebilir. • Bilgi işleme yöntemleri geleneksel programlamadan farklıdır. • Bilgiler, ağı tamamında saklanır. • Örnekleri kullanarak öğrenirler ve daha önce görülmemiş örnekler hakkında bilgi üretebilirler. • Örüntü (pattern) ilişkilendirme ve sınıflandırma yapabilirler. • Kendi kendine öğrenebilme ve organize etme yetenekleri vardır. • Eksik bilgi ile çalışabilmektedirler. • Hata toleransına sahiptirler. • Dereceli bozulma (Graceful degradation) gösterirler.	➤ Ağı davranışlarının açıklanamaması. ➤ Uygun ağ yapısının belirlenmesinde belli bir kural yoktur. ➤ Ağı parametre değerlerinin belirlenmesinde belli bir kural yoktur. ➤ Öğrenilecek problemin ağa gösterimi önemli bir problemdir ve donanım bağımlıdır.

5.4. Verilerin Hazırlanması

Bu tez çalışmasında Karadeniz Teknik Üniversitesi Tıp Fakültesi Farabi Hastanesi Acil Tıp Servisine göğüs ağrısı şikâyetiyle gelen, kalp krizi tanısı alan ve almayan 350 hasta verisi kullanılmıştır. Veri setindeki parametreler laboratuvar test sonuçları, epikriz raporları, anjiyografi sonuçları gibi evraklar uzman hekim danışmanlığında incelenerek elde edilmiştir. CK-MB ve troponin yanlış pozitif sonuç veren durumlar (polimiyozit/dermatomiyozit (kaslarda iltihaplanma), müsküler distrofiler (kas hastalığı), kronik böbrek yetmezliği ve kronik hemodiyaliz hastaları, son 24 saat içinde intramüsküler (kas içi) enjeksiyon yapılmış olan hastalar, son 3 gün içinde travma veya iskelet kası hasarı geçirmiş hastalar, hemolitik kan hastalığı olan hastalar ve şok tablosuyla gelen hastalar çalışma dışı tutulmuştur.

Hastalar kalp krizi olan (deney grubu) ve kalp krizi olmayan (kontrol grubu) diye iki gruba ayrılmıştır. Kalp krizi teşhisi Dünya Sağlık Teşkilatı (WHO) kriterlerine göre yapılmıştır (13).

6. BULGULAR

6.1. Veri Setinin Analizi

Tanımlayıcı analizler, sürekli değişkenlerde ortalama $\pm$ standart hata ve kategorik değişkenlerde n (%) kullanılarak verildi. Normal dağılım göstermeyen sürekli değişkenlerde gruplar arası farkı saptamada Mann Whitney U testi, kategorik değişkenlerde oranlar bakımından fark bulunup bulunmadığını belirlemede ise Ki-Kare testi kullanıldı. Korelasyon analizleri için Sperman korelasyon analizi kullanıldı.

Çalışma, 100'ü kadın 250'si erkek toplam 350 hasta üzerinde gerçekleştirilmiştir. Hastaların 192'si Kalp krizi tanısı alan, 158'i Kalp krizi tanısı almayan hastalar olarak gruplandırılmıştır. Kalp krizi tanısı alan ve almayan hastaların HS-Troponin ve CK-MB değerleri açısından bir fark olup olmadığı araştırılmıştır. ($p=0,0001$, $p=0,0001$) (Tablo 10).

Kalp krizi tanısı alan ve almayan hastaların cinsiyet, EKG değişikliği, ST segment değişikliği, kronik hastalık, aile öyküsü değişkenleri arasında fark olduğu anlaşılrken ($p<0,05$) ve kalp hastalığı açısından fark olmadığı tespit edilmiştir. ($p=0,95$) (Tablo 11). HS-Troponin ve CK-MB arasında ($r=0,633$, $p=0,0001$) pozitif yönde güçlü ve anlamlı bir ilişki mevcuttur (Tablo 12).

Kalp krizi tanısı alan ve almayan hastaların cinsiyet, EKG değişikliği, ST segment değişikliği, kronik hastalık, aile öyküsü ve kalp hastalığı öykülerini içeren demografik özellikleri ile ilgili bilgiler Tablo 6'da ve Tablo 7'de sunulmuştur. Kalp krizi tanısı alan ve almayan hastaların HS-Troponin ve CK-MB sonuçlarını içeren demografik özellikleri ile ilgili bilgiler Tablo 8'de ve Tablo 9'da sunulmuştur.

Hasta-dosya-no	Gogus-agrısı	Cinsiyet	CK-MB	HS-Troponin	ST-elevasyon	Kronik-hastalık	Kalp-hastalığı	Aile-oykusu	Tani
529	VAR	ERKEK	3,81	0,009	YOK	DM,HT	VAR	YOK	Kalp Krizi
1504735	VAR	KADIN	5,49	72,15	YOK	HT,OBEZ	YOK	VAR	Kalp Krizi
1513283	VAR	KADIN	12,94	196,1	YOK	HT	YOK	YOK	Kalp Krizi
1511720	VAR	ERKEK	5,83	71,53	VAR	YOK	YOK	VAR	Kalp Krizi
1510296	VAR	ERKEK	2,78	158,4	YOK	DM,OBEZ	YOK	YOK	Kalp Krizi
1510295	VAR	ERKEK	44,52	266,2	YOK	DM,OBEZ	YOK	YOK	Kalp Krizi
1509967	VAR	ERKEK	1,8	5,83	YOK	YOK	YOK	VAR	Kalp Krizi
1508535	VAR	ERKEK	2,99	24,35	YOK	YOK	YOK	YOK	Kalp Krizi
1507971	VAR	ERKEK	2,67	75,04	YOK	YOK	YOK	YOK	Kalp Krizi
1507159	VAR	ERKEK	29,67	157,3	YOK	YOK	YOK	YOK	Kalp Krizi
1505842	VAR	ERKEK	15,75	1577	YOK	DM	YOK	YOK	Kalp Krizi
1504735	VAR	KADIN	12,18	269,1	YOK	HT,HL	YOK	VAR	Kalp Krizi
1503345	VAR	ERKEK	5,77	80,65	VAR	HT	YOK	VAR	Kalp Krizi
1502902	VAR	KADIN	3,72	698,7	YOK	OBEZ,DM,HT	YOK	YOK	Kalp Krizi
1501368	VAR	ERKEK	46,41	989	VAR	YOK	YOK	YOK	Kalp Krizi
1500743	VAR	KADIN	181,1	1990	YOK	HT	YOK	YOK	Kalp Krizi
1500613	VAR	KADIN	1433	118,5	YOK	OBEZ,DM,HT	YOK	VAR	Kalp Krizi
1499908	VAR	ERKEK	2,17	28,61	YOK	HT,OBEZ	YOK	VAR	Kalp Krizi
1496469	VAR	ERKEK	33,96	8315	VAR	YOK	YOK	VAR	Kalp Krizi
1495687	VAR	ERKEK	296,9	1858	YOK	YOK	YOK	YOK	Kalp Krizi
1495526	VAR	ERKEK	4,82	85,42	YOK	OBEZ	YOK	YOK	Kalp Krizi
1494776	VAR	ERKEK	2,94	371,7	YOK	YOK	VAR	YOK	Kalp Krizi
1492533	VAR	KADIN	258,1	5157	YOK	HT,HL,DM,OBEZ	YOK	VAR	Kalp Krizi
1491959	VAR	ERKEK	30,23	290,1	YOK	YOK	YOK	YOK	Kalp Krizi
1489142	VAR	KADIN	2,12	681,8	YOK	HT,HL,DM,OBEZ	VAR	YOK	Kalp Krizi
1488959	VAR	ERKEK	48,03	1036	VAR	YOK	YOK	YOK	Kalp Krizi
1488907	VAR	ERKEK	5,18	92,91	YOK	YOK	YOK	YOK	Kalp Krizi
1487644	VAR	ERKEK	1,17	8,9	YOK	OBEZ	VAR	YOK	Kalp Krizi
1486935	VAR	KADIN	4,21	82,07	YOK	OBEZ	YOK	VAR	Kalp Krizi

Şekil 11. Deney gurubu veri seti örneği

Tablo 6. Kalp krizi tanısı alan hastalarda kategorik değişkenlerin dağılımları

		Frekans	Yüzde(%)	Geçerli Yüzde(%)	Kümülatif Yüzde(%)
Cinsiyet	Kadın	35	18,2	18,2	100
	Erkek	157	81,8	81,2	81,2
	Toplam	192	100	100	
EKG değişikliği	Var	146	76	76	100
	Yok	46	24	24	24
	Toplam	192	100	100	
ST segment değişikliği	Var	39	20,3	20,3	100
	Yok	153	79,7	79,7	79,7
	Toplam	192	100	100	
Kronik hastalık	Var	117	60,9	60,9	100
	Yok	75	39,1	39,1	39,1
	Toplam	192	100	100	
Kalp hastalığı	var	48	25	25	100
	yok	144	75	75	75
	Toplam	192	100	100	
Aile öyküsü	var	54	28,1	28,1	100
	yok	138	71,9	71,9	71,9
	Toplam	192	100	100	

Hasta-dosya-no	Gogus-agrisi	Cinsiyet	CK-MB	HS-Troponin	ST-elevasyon	Kronik-hastalik	Kalp-hastaligi	Aile-oykusu	Tani
1480800	VAR	ERKEK	5,74	46,49	YOK	YOK	YOK	YOK	Kalp krizi degil
1511848	VAR	ERKEK	1,75	4,54	YOK	YOK	YOK	YOK	Kalp krizi degil
1511730	VAR	ERKEK	5,9	26,83	YOK	YOK	YOK	YOK	Kalp krizi degil
1511173	VAR	ERKEK	10,97	12,67	YOK	YOK	YOK	YOK	Kalp krizi degil
1510928	VAR	ERKEK	1,18	25,48	YOK	YOK	YOK	YOK	Kalp krizi degil
1508455	VAR	KADIN	0,847	3,37	YOK	YOK	YOK	YOK	Kalp krizi degil
1508060	VAR	ERKEK	1,84	6,22	YOK	YOK	YOK	YOK	Kalp krizi degil
1508028	VAR	KADIN	2,26	4,97	YOK	YOK	YOK	YOK	Kalp krizi degil
1507914	VAR	KADIN	0,832	5,05	YOK	YOK	YOK	YOK	Kalp krizi degil
1507103	VAR	KADIN	1,59	5,11	YOK	YOK	YOK	YOK	Kalp krizi degil
1507083	VAR	ERKEK	2,07	4,64	YOK	YOK	YOK	YOK	Kalp krizi degil
1507018	VAR	ERKEK	2,43	5,44	YOK	YOK	YOK	YOK	Kalp krizi degil
1506985	VAR	ERKEK	1,67	5,49	YOK	YOK	YOK	YOK	Kalp krizi degil
1505769	VAR	ERKEK	4,83	3,2	YOK	YOK	YOK	YOK	Kalp krizi degil
1505762	VAR	ERKEK	3,36	16,59	YOK	YOK	YOK	YOK	Kalp krizi degil
1504797	VAR	ERKEK	3,38	5,54	YOK	YOK	YOK	YOK	Kalp krizi degil
1504553	VAR	ERKEK	65,31	111,1	YOK	YOK	YOK	YOK	Kalp krizi degil
1503554	VAR	ERKEK	0,76	9,22	YOK	YOK	YOK	YOK	Kalp krizi degil
1503380	VAR	ERKEK	0,842	7,27	YOK	YOK	YOK	YOK	Kalp krizi degil
1503330	VAR	KADIN	1,57	10,79	YOK	YOK	YOK	YOK	Kalp krizi degil
1502839	VAR	ERKEK	1,28	7,36	YOK	YOK	YOK	YOK	Kalp krizi degil
1501958	VAR	KADIN	1,39	4,02	YOK	YOK	YOK	YOK	Kalp krizi degil
1501377	VAR	KADIN	2,21	22,55	YOK	DM_HT	VAR	YOK	Kalp krizi degil
4187	VAR	KADIN	1,99	10,77	YOK	HT	VAR	YOK	Kalp krizi degil
6058	VAR	KADIN	3,91	0,067	YOK	HT	VAR	YOK	Kalp krizi degil
14472	VAR	KADIN	1,44	0,05	YOK	HT	VAR	VAR	Kalp krizi degil
20260	VAR	ERKEK	2,16	13,26	YOK	HEPATIT B	YOK	YOK	Kalp krizi degil
1500656	VAR	ERKEK	2,2	8,11	YOK	YOK	YOK	YOK	Kalp krizi degil
1500588	VAR	KADIN	1,33	3	YOK	YOK	YOK	YOK	Kalp krizi degil

Şekil 12. Kontrol gurubu veri seti örneği

Tablo 7. Kalp krizi tanısı almayan hastalarda kategorik değişkenlerin dağılımları

		Frekans	Yüzde(%)	Geçerli Yüzde(%)	Kümülatif Yüzde(%)
Cinsiyet	Kadın	65	41,1	41,1	100
	Erkek	93	58,9	58,9	58,9
	Toplam	158	100	100	
EKG değişikliği	Var	27	17,1	17,1	100
	Yok	131	82,9	82,9	82,9
	Toplam	158	100	100	
ST segment değişikliği	Var	0	0	0	100
	Yok	158	100	100	
	Toplam	158	100	100	
Kronik hastalık	Var	54	34,2	34,2	100
	Yok	104	65,8	65,8	65,8
	Toplam	158	100	100	
Kalp hastalığı	Var	39	24,7	24,7	100
	Yok	119	75,3	75,3	75,3
	Toplam	158	100	100	
Aile öyküsü	Var	11	7	7	100
	Yok	147	93	93	93
	Toplam	158	100	100	

Tablo 8. Kalp krizi tanısı alan hastalarda CK-MB ve HS-Troponin tanımlayıcı istatistikleri

Özellik	N	MEAN	SD	MİN	MAX
CK-MB	192	95,0545	260,6296	1,03	2313
HS-Troponin	192	807,7645	1547,915	0,01	8314,99

Tablo 9. Kalp krizi tanısı almayan hastalarda CK-MB ve HS-Troponin tanımlayıcı istatistikleri

Özellik	N	MEAN	SD	MİN	MAX
CK-MB	192	34,7327	371,631	0,3	4675
HS-Troponin	192	87,6766	378,545	0,01	3985

Tablo 10. Kalp krizi tanısı alan ve almayan hastaların HS-Troponin ve CK-MB değerleri açısından karşılaştırılması

HS-Troponin	N	Mean rank(SO)	Sum of ranks (ST)	U	z	p
Kalp Krizi Var	192	230,91	44334,5	4529,5	-11,296	0,0001
Kalp Krizi Yok	158	108,17	17090,5			
Toplam	350					
CK-MB	N	Mean rank(SO)	Sum of ranks (ST)	U	z	p
Kalp Krizi Yok	158	107,48	16982	4421	-11,409	0,0001
Kalp Krizi Var	192	231,47	44443			
Toplam	350					

HS-Troponin ve CK-MB aritmetik ortalamalarının Kalp Krizi tanısı alan ve almayan hastalara göre anlamlı bir farklılık gösterip göstermediğini belirlemek amacıyla

yapılan Mann Whitney U testi sonucunda, aralarındaki farkın istatistiksel olarak anlamlı olduğu bulunmuştur ($p=0,0001$, $p=0,0001$) (Tablo 10).

Tablo 11. Ki-kare test sonuçları

Değişken	Ki-kare	<i>p</i>
Cinsiyet	21,18	0,00
EKG değişikliği	118,16	0,00
ST segment değişikliği	34,09	0,00
Kronik hastalık	23,78	0,00
Aile öyküsü	24,28	0,00
Kalp hastalığı	0,005	0,95

* $p < 0,05$

Cinsiyet, EKG Değişikliği, ST Segment Değişikliği, Kronik Hastalık, Aile Öyküsü, Kalp Hastalığı değişkenleri arasından yalnızca Kalp Hastalığının, kalp krizi tanısı alıp almamada fark oluşturmadığı anlaşılmıştır ($p=0,95$) (Tablo 11).

Tablo 12. CK-MB VE HS-Troponin kolerayson ilişki analizi ile değerlendirmesi

Değişken	N	r	p
HS-Troponin			
CK-MB	350	0,633	0,0001

HS-Troponin ve CK-MB arasında ($r=0,633$, $p=0,0001$) pozitif yönde güçlü ve anlamlı bir ilişki mevcuttur (Tablo 12).

Yapılan tez çalışmasında veri setindeki cinsiyet, EKG değişikliği, ST segment değişikliği, kronik hastalık, aile öyküsü, CK-MB ve HS-Troponin parametrelerinden hastanın aciliyeti ve bilinci yerinde olmama durumları da göze alınarak modellerin geliştirilmesinde cinsiyet, EKG değişikliği, ST segment değişikliği, CK-MB ve HS-Troponin parametreleri kullanılmıştır. Modellerin geliştirilmesinde, Karadeniz Teknik Üniversitesi Tıp Fakültesi Farabi hastanesi acil servisinden alınan 350 verinin 205'i eğitim seti, kalan 145'i de test seti olarak kullanılmıştır. Bu veri setleri R rastgele örnekleme fonksiyonu kullanılarak oluşturulmuştur ve kategorik veriler numerik olarak kodlanmıştır. Train ve test setleri örnekleri aşağıdaki şekillerde verilmiştir.

cinsiyet	CK.MB	HS.Troponin	EKG.degisikligi	ST.elevasyon	Tani
0	135	129	1	1	1
0	141	118	0	0	1
0	143	137	0	0	1
0	144	6	1	0	1
0	147	109	1	1	1
0	148	60	1	0	1
0	149	149	1	1	1
0	151	7	1	0	1
0	154	51	0	0	1
0	156	92	0	0	1
0	158	35	1	0	1
0	162	54	1	0	1
0	4675	36	1	0	0
1	0.303	51	0	0	0
1	0.64	107	0	0	0
1	0.725	43	0	0	0
1	0.748	95	0	0	0
1	0.777	43	0	0	0
1	0.793	43	0	0	0
1	0.877	43	0	0	0
1	0.932	50	0	0	0
1	0.945	43	0	0	0
1	1.13	43	0	0	0
1	1.15	43	0	0	0
1	1.19	73	0	0	0
1	1.23	43	0	0	0
1	1.31	43	0	0	0
1	1.33	43	0	0	0


Şekil 13. Train set örneği

cinsiyet	CK.MB	HS.Troponin	EKG.degisikligi	ST.elevasyon	Tani
0	134	141	1	0	1
0	136	8	1	1	1
0	137	81	1	0	1
0	138	59	1	0	1
0	140	133	1	0	1
0	142	86	1	1	1
0	145	138	1	1	1
0	146	113	1	0	1
0	148	60	1	0	1
0	152	17	0	0	1
0	157	92	0	0	1
0	159	120	1	0	1
0	160	83	1	0	1
0	161	2	1	0	1
0	163	128	1	0	1
1	0.832	85	0	0	0
1	0.837	43	0	0	0
1	0.847	48	0	0	0
1	0.857	47	0	0	0
1	0.888	44	0	0	0
1	0.911	66	0	0	0
1	0.932	50	0	0	0
1	1.27	71	0	0	0
1	1.44	5	0	0	0
1	3.44	77	1	0	0
1	3.91	6	0	0	0
1	5.95	80	0	0	0
1	10.77	109	0	0	0

Şekil 14. Test set örneği

6.2. Destek Vektör Makinesi Modeline Dair Bulguları

Yapılan çalışmada linear, radyal, polynomial ve gmoid olmak üzere farklı kernel fonksiyonları kullanılarak 4 farklı DVM modeli geliştirilmiştir. Geliştirilen modellerin performansları ROC eğrisi kullanılarak karşılaştırılmıştır.



Şekil 15. Farklı kernel fonksiyonları ile geliştirilen DVM modellerine ait performans karşılaştırması

ROC eğrisinin altında kalan alan AUC (Are Under Curve) olarak adlandırılmaktadır. AUC değerinin büyük olması geliştirilen tahmin modelin tahmin performansının iyi olduğu anlamına gelmektedir. Buna göre, Şekil 19.'a bakıldığında sigmoid kernel ile geliştirilen DVM modeli için AUC değeri %80.8 iken, diğer kernel modelleri %81.3'tür.

Geliştirilen DVM modellerine ait parametre bilgileri aşağıdaki tabloda verilmiştir.

Tablo 13. Kernel fonksiyonları parametreleri tablosu

	Sigmoid	Radial	Linear	Polynomial
Cost	1	1	1	1
Gamma	0,2	0.1666666667	0.2	0,2
Degree	-	-	-	3
Coef.0	0	-	-	0

Tablo 14. Model ve gerçek sonuçların karşılaştırılması. TP (True Pozitive), TN (True Negative), FP (False Pozitive), FN (False Negative)

Gerçek Sonuçlar	Modelin Tahmin Sonuçları	
	Kalp krizi	Kalp krizi değil
Kalp krizi	77(TP)	20(FN)
Kalp krizi değil	8(FP)	40(TN)

En yüksek performansı gösteren DVM modellerinden radial kernel modeli seçilerek duyarlılık ve özgüllük değerleri aşağıda verilen formüllerle hesaplanmıştır (17).


$$\text{Duyarlılık (sensitivity)} = \frac{TP}{(TP+FN)} \quad (6.1)$$

$$\text{Özgüllük (specificity)} = \frac{TN}{(TN+FP)} \quad (6.2)$$

Buna göre, geliştirilen en iyi DVM modeli için 145 test verisi üzerinde %79 duyarlılık ve %83 özgüllük değerleri elde edilmiştir.

6.3. Karar Ağacı Modeline Dair Bulgular

Geliştirilen karar ağacı modelinde yaygın olarak kullanılan C5.0 algoritması kullanılmıştır. Modelin R programıyla elde edilen ağaç görüntüsü Resim 5'te verilmiştir.



Şekil 16. Kalp krizi karar destek sistemi için geliştirilen karar ağacı modeli

```

class specified by attribute 'outcome'

Read 205 cases (6 attributes) from undefined.data

Decision tree:

CK.MB <= 5.98: 0 (95/4)
CK.MB > 5.98:
...CK.MB > 48.35: 1 (64/1)
  CK.MB <= 48.35:
    ...EKG.degisikligi = 0: 0 (22/9)
      EKG.degisikligi = 1:
        ...cinsiyet = 0: 1 (15/3)
          cinsiyet = 1:
            ...HS.Troponin <= 48: 1 (7)
              HS.Troponin > 48: 0 (2)

Evaluation on training data (205 cases):

      Decision Tree
      -----
      Size      Errors
      6      17 ( 8.3%)  <<

Attribute usage:
100.00% CK.MB
22.44% EKG.degisikligi
11.71% cinsiyet
4.39% HS.Troponin

Time: 0.0 secs

```

Şekil 17. Karar ağacı modeli R program özeti


Geliştirilen karar ağacı modeline ait duyarlılık ve özgüllük değerleri sırasıyla %91.7 ve %97.9'tür. Test setindeki kalp krizi tanısı alan 97 hasta verisinin 89'unu doğru sınıflandırmıştır.

Tablo 15. Model ve gerçek sonuçların karşılaştırılması

Gerçek Sonuçlar	Modelin Tahmin Sonuçları	
	Kalp krizi	Kalp krizi değil
Kalp krizi	89(TP)	8(FN)
Kalp krizi değil	1(FP)	47(TN)

6.4. Yapay Sinir Ağı Modeline Ait Bulgular

Yapılan tez çalışmasında, R programı “neuralnetwork” paketi yardımıyla çok katmanlı yapay sinir ağı modeli geliştirilmiştir. Modelin R program çıktısı aşağıdaki şekilde verilmiştir.



Şekil 18. Kalp krizi karar destek sistemi için geliştirilen YSA modeli

Geliştirilen sinir ağı modeli 145 test verisi üzerinde %98 duyarlılık ve %93.7 özgüllük değerleri ile başarılı sonuç vermiştir. Kalp krizi tanısı alan 97 hasta verisinin 96’sını doğru sınıflandırmış, sadece 1 hastayı kaçırmıştır.

Tablo 16. Model ve gerçek sonuçların karşılaştırılması

Gerçek Sonuçlar	Modelin Tahmin Sonuçları	
	Kalp krizi	Kalp krizi değil
Kalp krizi	96(TP)	1(FN)
Kalp krizi değil	3(FP)	45(TN)

6.5. Geliştirilen Tanı Modellerinin Karşılaştırılması


Yapılan tez çalışmasında, kalp krizi karar destek sistemi için YSA, DVM ve karar ağacı yöntemleri kullanılarak üç farklı tanı modeli geliştirilmiştir. Geliştirilen modellere ait duyarlılık ve özgüllük değerleri aşağıdaki tabloda verilmiştir.

Tablo 17. Geliştirilen modellere ait duyarlılık ve özgüllük değerleri

	Duyarlılık (%)	Özgüllük(%)
YSA	%98	%93.7
DVM	%79	%83
Karar Ağacı	%91.7	%97.9

Tablo 17’de görüldüğü gibi DVM en kötü sonucu verirken, YSA modeli %98 ile en yüksek duyarlılığa, karar ağacı modeli ise %97.9 ile en yüksek özgüllüğe sahiptir. Kalp krizi tanısının kaçırılmaması yani FP oranının düşük olması istendiğinden duyarlılığın yüksek olması özgüllüğün ise optimum olması önemlidir. Bu nedenle geliştirilen YSA tanı modeli %98 duyarlılık ve %93.7 özgüllük değerleri ile kalp krizi karar destek sistemi için en iyi model olarak görülmektedir.

Bununla birlikte geliştirilen modellere ait ROC eğrileri ve AUC değerleri Şekil 19’de verilmiştir.



řekil 19. Geliřtirilen tanı modellerinin performans karřılařtırması

řekil 19’da görüldüğü gibi YSA tanı modeli %98.3 AUC değeri ile en iyi sonucu vermektedir.

7. TARTIŞMA ve SONUÇ

Günümüzde yapılan uluslararası çalışmalarda makine öğrenmesi yaklaşımlarıyla sağlık alanında bilgisayar destekli tanı sistemleri oldukça popülerdir. Özellikle teknolojinin kullanılmasıyla hem kaliteli bir teşhis hem de daha hızlı tıbbi müdahale yapılabilmesi sağlanmaktadır. Bu tez çalışmasında günümüzün önemli hastalıklarından olan kalp krizi ele alınmıştır. Bu amaçla, makine öğrenmesi yaklaşımlarına dayalı YSA, DVM ve karar ağacı yöntemleri kullanılarak hekimlere yardımcı olabilecek bir kalp krizi karar destek sistemi geliştirilmiştir.

Yapılan tez çalışmasında kalp krizi tanısı alan ve almayan hasta verilerine ait EKG değişikliği, ST segment değişikliği, cinsiyet, HS-troponin ve CK-MB parametreleri kullanılarak kalp krizi tanısı alıp almadığına (MI(+)) veya MI((-)) otomatik karar verebilen akıllı bir karar destek sistemi geliştirilmiştir. Veri setindeki 350 hasta verisinin 205'i eğitim, 145'i test seti olmak üzere ikiye ayrıldıktan sonra YSA, DVM ve karar ağacı yöntemleri kullanılarak üç farklı karar destek modeli geliştirilmiştir. Geliştirilen DVM modeli için 4 farklı kernel fonksiyonu uygulanarak en iyi DVM modeli belirlenmiştir ve 145 test verisi üzerinde %79 duyarlılık, %83 özgüllük değerleri elde edilmiştir. Çalışmamızda geliştirilen karar ağacı modeline ait duyarlılık ve özgüllük değerleri ise sırasıyla %91.7 ve %97.9 olarak elde edilmiştir. YSA modeli için elde edilen duyarlılık değeri %98.3, özgüllük değeri ise %93'tür. Sonuçlardan görüldüğü üzere geliştirilen modeller arasında en iyi performansı YSA modeli göstermiştir.

Literatürde yapılan benzer bir çalışmada (4) karar ağacı yöntemi kullanılarak geliştirilen kalp krizi tanı sisteminde 69 test verisi üzerinde %91 duyarlılık ve %90 özgüllük değerleri elde edilmiştir. Yapılan bir başka çalışmada ise 50 kalp krizi tanısı alan ve 11 kalp krizi tanısı almayan hasta üzerinde karar ağacı yöntemiyle sınıflandırma yapılmış ve %100 duyarlılık ve özgüllük ile doğru sınıflandırılmıştır (3). Bir diğer çalışmada, radial tabanlı (RBF) YSA ve DVM yöntemleri kullanılarak kalp hastalığı teşhisi yapabilen iki model geliştirilmiştir. 139 kalp ve 78 normal hasta verisi üzerinde RBF modeli ile %84.06 duyarlılık ve %88.5 özgüllük, DVM modeli ile %82.40 duyarlılık ve % 82.10 özgüllük değerleri elde edilmiştir (47). Yapılan tez çalışması literatürdeki benzer çalışmalar ile karşılaştırıldığında kullanılan parametrelerin farklı

olması, test veri sayısının yüksek olması ve elde edilen %98 duyarlılık, %93.7 özgüllük değerleri ile öne çıkmaktadır.

Geliştirilen kalp krizi karar destek sistemi kullanılarak göğüs ağrısı ile acil servise başvuran hastaların kalp krizi geçirme olasılığına karar verme sürecinde hekime yardımcı olunabilmesi, kesin tanının koyulabilmesi için tekrarlanan laboratuvar tetkikleri ve EKG ölçümlerinin sayısının da azaltılması hedeflenmektedir. Bununla birlikte geliştirilen tanı modelinde kullanılan parametrelerin ilerleyen yıllar içerisinde taşınabilir cihazlar yardımı ile alınabilmesi halinde hasta daha ambulansla iken kalp krizi geçirip geçirmediği ön tanısı koyulabilecek ve hastanın vakit kaybetmeden ilk müdahalesi yapılabilecektir. Ayrıca, aldığı tanıya göre hastanın sevkıyatı ona uygun bir hastaneye vakit kaybetmeden gerçekleştirilebilir. Böylece kalp krizine bağlı ölüm oranını azaltmaya yardımcı olunabilecektir.

Ülkemizde oldukça sınırlı olan bu tür çalışmaların sayısının arttırılabilmesi ve benzer çalışmaların geliştirilmesi amacıyla yapılan çalışmanın diğer çalışmalara ışık tutması beklenmektedir.

8. KAYNAKLAR

1. Türkiye Kalp ve Damar Hastalıkları Önleme ve Kontrol Programı Eylem Planı. (2015) T.C Sağlık Bakanlığı Türkiye Halk Sağlığı Kurumu, 988, 2015.
2. Dangare CS, Apte SS (2012). A Data minning approach for prediction of heart disease using neural networks. International Journal of Computer Engineering and Technology 3: 30-40.
3. Doğan Ş, Türkoğlu İ, Yavuzkır M (2007). Heart attack detection from cardiac by using decision trees. eJournal of New World Sciences Academy 2: 39-50.
4. Mair J, Smidt J, Lechleitner P, Dienstl F, Puschendorf B (1995). A decision tree for the early diagnosis of acute myocardial infarction in nontraumatic chest pain patients at hospital admission. The Journal of Emergency Medicine 14: 1502-1509.
5. Durairaj M, Revathi V (2015). Prediction of heart disease using back propagation mlp algorithm. International Journal of Scientific & Technology Research 4: 235-239.
6. Sunila, Panday P, Godara N (2012). Decision support system for cardiovascular heart disease diagnosis using improved multilayer perceptron. International Journal of Computer Applications 45: 12-20.
7. Collinson PO, Premachandram S, Hashemiet K (2000). Prospective audit of incidence of prognostically important myocardial damage in patients discharged from emergency department. British Medical Journal 324: 1702-1705.
8. Daga LC, Kaul U, Mansoor A (2011). Approach to STEMI and NSTEMI. Journal of The Association of Physicians of India 59: 19-25.
9. Pandey R, Gupta NK, Wander GS (2011). Diagnosis of acute myocardial infarction. Journal of The Association of Physicians of India 59: 8-13.
10. Murat M (2012). ST yükselmesi olmayan akut koroner sendromlar. Deneysel ve Klinik Tıp Dergisi 29:133-13.
11. Vestraete M (2000). Third-generation thrombolytic drugs. American Journal of Med 109: 52-58.
12. Topol EJ (2008). Acute Coronary Syndromes. Akut koroner sendromlar. 3rd ed. Çeviren: Kozan Ö, Avrupa Tıp Kitapçılık Ltd. Şti.İstanbul; 180-190.

13. Storrow AB, Gibler WB (2000). Chest pain centers: diagnosis of acute coronary syndromes. *Ann Emerg Med* 35: 449-461.
14. Heart Attack Anatomy (2016) [online].
<https://www.flickr.com/photos/gandhiji40/395241000>.
15. Candan İ, Oral D (2002) *Kardiyoloji*. 1. baskı, Ankara Tıp Yayınları, Ankara; 605-787.
16. Zimmerman J, Fromm R, Meyer D, Boudreaux A, Wun CC, Smalling R, Davis B (1999). Diagnostic marker cooperative study for the diagnosis of myocardial infarction. *Circulation* 99: 1671-1677.
17. Winter RJ, Koster W, Sturk A, Sanders GT (1995). Value of myoglobin, troponin T and CK-MB in ruling out an acute myocardial infarction in the emergency room. *Circulation* 92: 3401-3407.
18. Enar R (2005). *Kanıtı Dayalı Akut Miyokard İnfarktüsü Kitabı*. Cilt 1. Nobel Tıp Kitabevleri Ltd. Sti. No: 111, İstanbul; 5-135.
19. Griffin BP, Topol JE (2007). *Manuel of Cardiovascular Medicine*. *Kardiyovasküler Hastalıklar El Kitabı*. 2nd ed. Çeviren: Erol Ç, Atalar E, Güneş Tıp Kitabevleri, Ankara; 3-98
20. Enar R (2004). *Akut Miyokard İnfarktüsü Trombo Kardiyoloji*. Nobel Tıp Kitabevleri Ltd. Sti. No: 111, İstanbul; 730-769.
21. Enar R (2006). *Akut Miyokard Enfarktüsü Teşhis ve Tedavi Kılavuzu*. Nobel Tıp Kitabevleri Ltd. Sti. No:111,İstanbul;1-20.
22. Sinus Rhythm Labels. (2016) [online].
<https://commons.wikimedia.org/wiki/File:SinusRhythmLabels.svg>.
23. Hindistan S, Nural N (2010). Miyokard infarktüsünde kadın ve erkek arasındaki farklılıklar. *Maltepe Üniversitesi Hemşirelik Bilim ve Sanatı Dergisi* 1: 66-72.
24. Kalp hastalıkları önlenebilir (2016) [online].
<http://webb.deu.edu.tr/halksagligi/?SID=ContentBlogger&ID=114&PID=HalkaYonelik&TID=G%C3%BCncel%20Konular%20%C2%BB%20Halka%20y%C3%B6nelik>.
25. Balaban ME, Kartal E (2015). *Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları*. Çağlayan Kitabevi No.3, İstanbul; 15-54.



26. Lantz B (2015). Machine Learning With R. 2nd ed. Packt Publishing. Brimingham: UK, 1-27.
27. Machine Learning Technique (2016) [online].
https://commons.wikimedia.org/wiki/File:Machine_Learning_Technique..JPG.
28. Güner N, Çomak E (2011). Mühendislik öğrencilerinin matematik derslerindeki başarısının destek vektör makineleri kullanılarak tahmin edilmesi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi 2: 87-96.
29. Kavzoğlu T, Çölkesen İ (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. Harita Dergisi 144: 73-82.
30. Svm Max Sep Hyperplane With Margin. (2016) [online].
https://commons.wikimedia.org/wiki/File:Svm_max_sep_hyperplane_with_margin.png.
31. Yılmaz Akşehirli Ö, Ankaralı H, Aydın D, Saraçlı Ö (2013). Tıbbi tahminde alternatif bir yaklaşım: Destek vektör makineleri. Türkiye Klinikleri Journal of Biostatistics 1: 19-28.
32. Kernel Machine. (2016) [online].
https://commons.wikimedia.org/wiki/File:Kernel_Machine.png.
33. Berry MJA, Linoff GS (2000). Mastering Data Mining: The Art and Science of Customer Relationship. 1st ed. Wiley Computer Publishing, New York; 111-119.
34. Çalış A, Kayapınar S, Çetinyokuş T (2014). Veri madenciliğinde karar ağacı algoritmaları ile bilgisayar ve internet güvenliği üzerine bir uygulama. Endüstri Mühendisliği Dergisi 3-4: 2-19.
35. Han J, Kamber M, Pei J (2000). Data Mining Concepts. 3rd ed. Morgan Kaufmann Publishers, San Francisco, USA; 330-348.
36. Decission Trees. (2016) [online].
<http://science.slc.edu/~jmarshall/courses/2005/fall/cs151/lectures/decision-trees/>.
37. Özekeş S (2003). Veri madenciliği modelleri ve uygulama alanları. İstanbul Ticaret Üniversitesi Dergisi 3: 65-82.
38. Rokach L, Maimon O (2014). Data Mining with Decision Trees: Theory and Applications. 2nd ed. World Scientific Publishing, Singapore; 1-16.

39. Öztemel E (2012).Yapay Sinir Ağları. Üçüncü baskı. Papatya Yayıncılık Eğitim AŞ. İstanbul, No. 11/3, 29-59.
40. Gönül Y, Ulu Ş, Bucak A (2015). Yapay sinir ağları ve klinik araştırmalarda kullanımı. Genel Tıp Dergisi 25: 104-111.
41. Popular Science: Neural Networks. (2016) [online].
<https://steemit.com/popularscience/@puhoshville/popularscience-neural-networks-how-does-it-work-and-my-appeal-to-steemians>.
42. Artificial Neuron Model (2016) [online].
https://commons.wikimedia.org/wiki/File:ArtificialNeuronModel_english.png.
43. Yılmaz B (2015). Akarçay havzasında çözünmüş oksijen değerlerinin yapay sinir ağları ile belirlenmesi. Uzmanlık tezi, T.C. Orman ve Su işleri Bakanlığı, Ankara.
44. Nabiyyev V (2012). Yapay Zeka. Dördüncü baskı. Seçkin Yayıncılık, No.21, Ankara; 565-590.
45. Kaynar O, Taştan S (2009). Zaman serisi analizinde MLP yapay sinir ağları ve arıma modelinin karşılaştırılması. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 33: 161-172.
46. Neural Network. (2016) [online]. <http://www.texample.net/tikz/examples/neural-network/>.
47. Ghumbre S, Patil C, Ghatol A (2011). Heart Disease Diagnosis using Support Vector Machine. International Conference on Computer Science and Information Technology (ICCSIT'2011), Pattaya, December 2011, 84-88.

9. ETİK KURUL ONAYI

KARAR BİLGİLERİ	Karar No: 4	Tarih: 09/05/2016
	Y.Doç.Dr.Burçin KURT'un sorumluluğunda yürütülmesi planlanan Yük.Lis.Öğr.İlknur BUÇAN KIRKBİR'e ait "Kalp Krizi Karar Destek Sistemi" başlıklı 2016/45 no.lu ve yukarıda başvuru bilgileri verilen araştırma/tez başvuru dosyası ile ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş, gerçekleştirilmesinde etik sakınca bulunmadığına; toplantıya katılan etik kurul üyelerinin oy birliği ile karar verilmiştir.	

KTÜ TIP FAKÜLTESİ BİLİMSEL ARAŞTIRMALAR ETİK KURULU KARAR FORMU	
ÇALIŞMA ESASI	Klinik Araştırmalar Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu
BAŞKANIN UNVANI / ADI / SOYADI:	Prof.Dr.Faruk AYDIN

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet	İlişki *	Katılım **	İmza
Prof.Dr.Faruk AYDIN Başkan:	Tıbbi Mikrobiyoloji	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof.Dr.Gamze ÇAN Başkan Yrd.	Halk Sağlığı	KTÜ Tıp Fakültesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Prof.Dr.S.Caner KARAHAHAN Üye:	Tıbbi Biyokimya	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☒	İZİNLİ
Prof.Dr.S. Murat KESİM Raportör:	Farmakoloji	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof.Dr.Yılmaz BÜLBÜL Üye:	Göğüs Hastalıkları	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Doç.Dr. Murat LİVAOĞLU Üye:	Plastik, Rekons. ve Estetik Cer	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Doç.Dr.Şafak ERSÖZ Üye:	Patoloji	KTÜ Tıp Fakültesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Doç.Dr. Evrim Ö. KARAGÜZEL Üye:	Ruh Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Prof.Dr.Murat ÇAKIR Üye:	Çocuk Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	

* :Araştırma ile İlişki

** :Toplantıda Bulunma

10. ÖZGEÇMİŞ

Soyadı, Adı : BUÇAN KIRKBİR, İlknur

Uyruğu : T.C.

Doğum tarihi ve yeri: RİZE 12.12.1985

Medeni hali : Evli

E-Posta : ilknurbucan@gmail.com

Yazışma adresi : Karadeniz Teknik Üniversitesi, Sağlık Kültür Daire Başkanlığı,
Merkez, Trabzon

EĞİTİMBİLGİLERİ

Derece	Mezun Olduğu Kurumun Adı	Mezuniyet Yılı
--------	--------------------------	----------------

Yüksek Lisans	Karadeniz Teknik Üniversitesi	Devam ediyor
----------------------	-------------------------------	--------------

Sağlık Bilimleri Enstitüsü

Biyoistatistik ve Tıp Bilişimi

Anabilim Dalı

Lisans	Karadeniz Teknik Üniversitesi	2010
---------------	-------------------------------	------

Trabzon Sağlık Yüksek Okulu

Hemşirelik Bölümü

Lise	Ardeşen Yabancı Dil Ağırlıklı Lise	2003
-------------	------------------------------------	------

YABANCI DİL İngilizce