

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**



**İRİS GÖRÜNTÜLERİ KULLANILARAK MAKİNE
ÖĞRENMESİ İLE KORONER ARTER HASTALIĞININ
TESPİTİ**

Doktora Tezi

Ferdi ÖZBİLGİN

Danışman

Doç. Dr. Çetin KURNAZ

SAMSUN
2023

TEZ KABUL VE ONAYI

Ferdi ÖZBİLGİN tarafından, Doç. Dr. Çetin KURNAZ danışmanlığında hazırlanan “İRİS GÖRÜNTÜLERİ KULLANILARAK MAKİNE ÖĞRENMESİ İLE KORONER ARTER HASTALIĞININ TESPİTİ” başlıklı bu çalışma, jürimiz tarafından 19.9.2023 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Doktora Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	Sonuç
Başkan	Prof. Dr. Gülay TEZEL Konya Teknik Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye (Danışman)	Doç. Dr. Çetin KURNAZ Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı	☒ Kabul ☐ Ret
Üye	Prof. Dr. Mahmut HEKİM Tokat Gaziosmanpaşa Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı	☒ Kabul ☐ Ret
Üye	Doç. Dr. Hilal ESER ÖZTÜRK Ondokuz Mayıs Üniversitesi Göz Hastalıkları Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi Begüm KORUNUR ENGİZ Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı	☒ Kabul ☐ Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Ahmet TABAK
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Doktora tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi?

Evet ☒

Hayır ☐

19/09/2023
Ferdî ÖZBİLGİN

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : İRİS GÖRÜNTÜLERİ KULLANILARAK MAKİNE ÖĞRENMESİ İLE KORONER ARTER HASTALIĞININ TESPİTİ

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 20.06.2023 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 10

Tek kaynak oranı : % 4 çıkmıştır.

19/09/2023
Doç. Dr. Çetin KURNAZ

ÖZET

İRİS GÖRÜNTÜLERİ KULLANILARAK MAKİNE ÖĞRENMESİ İLE KORONER ARTER HASTALIĞININ TESPİTİ

Ferdi ÖZBİLGİN

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Doktora, Eylül/2023

Danışman: Doç. Dr. Çetin KURNAZ

Koroner Arter Hastalığı (KAH), kalp kaslarını besleyen koroner arter damarların daralması ya da tıkanması ile kan akışının sınırlanması sonucunda ortaya çıkmaktadır. En yaygın ve en yüksek ölüm oranına sahip kalp hastalığıdır. KAH'ın erken teşhisi hastalığın ilerlemesini önleyebilmekte ve tedavi sürecini kolaylaştırmaktadır. Bu tez çalışmasında, iris görüntüleri kullanılarak KAH'ın invaziv olmayan teşhisi için iris analizi ve makine öğrenmesi tabanlı bir yöntem önerilmiştir. İris analizi görüntü işleme yöntemleri ile iridolojinin harmanlanmasını içermektedir. Çalışmada KAH tahmini için hasta grubunda 155 ve hasta olmayan kontrol grubunda 126 gönüllü yer almaktadır. Toplamda 281 gönüllüye ait göz görüntüleri ve biyodemografik veriler Giresun Üniversitesi Eğitim-Araştırma Hastanesi Kardiyoloji Polikliniği'ndeki uzman hekimlerin yönlendirmeleri ile alınmıştır.

Tez çalışmasında iris ve biyodemografik öznitelikler olmak üzere iki farklı öznitelik grubu yer almaktadır. İris özniteliklerinin çıkarılmasına ait süreçler görüntü işleme teknikleri ile gerçekleştirilmiştir. Bu süreç, göz görüntüleri içerisinden iris konumlarının tespit edilmesi için İntegral-Diferansiyel operatörü yöntemi kullanılarak başlamaktadır. Bu yöntem ile iç ve dış sınırları belirlenen iris Rubber Sheet tekniği ile dikdörtgen formata dönüştürülerek standardize edilmiştir. Jensen iridoloji haritası referans alınarak iristeki kalp bölgesi kırılmış ve analiz bölgesi elde edilmiştir. Analiz bölgesine adaptif histogram eşitleme ile görüntü iyileştirme yapılmıştır. Öznitelik çıkarma işlemi için analiz bölgesine 2 seviye dalgacık dönüşümü uygulanmış ve 8 alt bileşene beş adet birinci dereceden istatistiksel, 22 adet Gri Seviye Birlikte Oluşum Matrisi (Gray Level Co-Occurrence Matrix, GLCM) ve 7 adet Gri Seviye Koşu Uzunluğu Matrisi (Gray Level Run Length Matrix, GLRLM) öznitelikleri elde edilmiştir. Her alt bileşen için 34 öznitelik olmak üzere toplamda 272 öznitelik çıkarılmıştır. Relieff öznitelik seçme yöntemi ile en iyi öznitelikler belirlenerek beş farklı makine öğrenmesi sınıflandırıcısı ile sınıflandırma gerçekleştirilmiştir. Elde edilen öznitelikler Relieff öznitelik seçme algoritması ile belirlenen iyi özniteliklere göre sınıflandırma sürecine aktarılmıştır. Naive Bayes (NB), Karar Ağaçları (Decision Trees, DT), k-En Yakın Komşu (k-Nearest Neighbors, k-NN), Destek Vektör Makineleri (Support Vector Machine, SVM) ve Yapay Sinir Ağları (Artificial Neural Networks, ANN) olmak üzere beş farklı sınıflandırıcı ailesi kullanılarak sınıflandırma aşaması gerçekleştirilmiştir. 10 katlı çapraz doğrulama ile test verilerine ait performans değerlendirmeleri de doğruluk, duyarlılık, özgüllük, kesinlik, F_1 ölçütü ve AUC metriklerine göre yapılmıştır. Sadece iris parametreleri ile performans ölçümü gerçekleştirildiği gibi iris özniteliklerine gönüllülere ait fizyolojik parametrelerin eklenmesi ile de analizler tekrardan yapılmıştır. Bu çalışmada yapılan tüm analizler MATLAB programlama dili kullanılarak gerçekleştirilmiştir.

Önerilen yöntemde, iris analizleri sonucunda Doğrusal SVM yöntemine ait modelde %94.05 ile en yüksek değer elde edilmiştir. SVM'yi %92.86 ile ANN, %89.29 ile NB, %88.1 ile DT ve son olarak da %86.9 ile k-NN sınıflandırıcısı izlemektedir. SVM yöntemi özgüllük, kesinlik ve F_1 ölçütü metriklerinde de sırasıyla %92.31, %93.48 ve %94.51 ile en iyi sonucu vermiştir. Duyarlılık metriğinde %100 ile k-NN en iyi sınıflandırıcı olurken ANN'ye ait modelde AUC değeri %97.01 ile en başarılı model olmuştur.

İris ve biyodemografik verilerin birlikte yer aldığı analiz sonucunda ise metrik değerlerinin arttığı gözlemlenmiştir. Doğruluk metriği yine SVM modelinde %95.24'e yükselmiştir. SVM modelinde özgüllük, kesinlik, F_1 ölçütü ve AUC metriklerinde de sırasıyla %94.87, %95.56, %95.56 ve %98.12 ile en iyi sonucu vermiştir. Duyarlılık metriğinde %100 ile k-NN yine en iyi sınıflandırıcı olmuştur.

Bu çalışmada, yeni bir model geliştirilmiş ve yaygın bir kardiyovasküler durum olan KAH tespiti bağlamında performansı değerlendirilmiştir. Önerilen model, daha önce KAH tespiti için kullanılmış olan mevcut modellerle karşılaştırılmıştır. Karşılaştırma sonuçları, önerilen modelin KAH tespitindeki başarı oranı açısından mevcut modellerden daha iyi performans gösterdiğini ortaya koymuştur. Bu bulgular, önerilen modelin KAH'ı doğru bir şekilde tespit etmedeki etkinliğini ve üstünlüğünü göstermekte, böylece bu alandaki önceki çalışmaların aksine kapsamlı ve başarılı yapısını ortaya koymaktadır.

Anahtar Sözcükler: İris, Biyodemografik, İridoloji, Koroner arter hastalığı, Görüntü işleme, Makine öğrenmesi.

ABSTRACT

CORONARY ARTERY DISEASE DETECTION BASED ON IRIS IMAGES USING MACHINE LEARNING

Ferdi ÖZBİLGİN

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Electrical and Electronics Engineering

Ph.D., September/2023

Supervisor: Assoc. Prof. Dr. Çetin KURNAZ

Coronary Artery Disease (CAD) occurs when the coronary arteries that supply the heart muscles become narrowed or blocked, limiting blood flow. It is the most common heart disease with the highest mortality rate. Early diagnosis of CAD can prevent the progression of the disease and facilitate the treatment process. In this thesis, an iris analysis and machine learning-based method is proposed for the non-invasive diagnosis of CAD using iris images. Iris analysis involves the blending of image processing methods and iridology. The study includes 155 volunteers in the patient group and 126 volunteers in the non-patient control group for CAD prediction. Eye images and biometric data of a total of 281 volunteers were obtained with the guidance of specialist physicians at the Cardiology outpatient clinic of Giresun University Training and Research Hospital.

In this thesis, two different sets of attributes are utilized: iris and biometric attributes. The process of extracting iris features was carried out using image processing techniques. This process begins by employing the Integral-Differential operator method to determine the iris locations from the eye images. The iris, with its inner and outer boundaries determined through this method, was standardized by converting it into a rectangular format using the Rubber Sheet technique. The analysis region was obtained by cropping the heart region in the iris, referencing the Jensen iridology map. Image enhancement was applied to the analysis region using adaptive histogram equalization. For feature extraction, a 2-level wavelet transform was applied to the analysis region, yielding five first-order statistical, 22 Gray Level Co-occurrence Matrix (GLCM), and seven Gray Level Run Length Matrix (GLRLM) features for eight subcomponents. A total of 272 attributes were extracted, comprising 34 attributes for each subcomponent. The best features were determined using the Relief feature selection method, and classification was performed using five different machine learning classifiers. The extracted features were transferred to the classification process based on the best features identified by the Relief feature selection algorithm. The classification phase employed five different classifier families: Naive Bayes (NB), Decision Trees (DT), k-Nearest Neighbor (k-NN), Support Vector Machines (SVM), and Artificial Neural Networks (ANN). 10-fold cross-validation was utilized to evaluate the performance of the test data, considering accuracy, sensitivity, specificity, precision, F₁ score, and AUC metrics. Performance measurements were conducted using iris parameters alone, as well as with the inclusion of physiological parameters of the volunteers as additional iris attributes. All analyses in this study were performed using the MATLAB programming language.

In the proposed method, the highest value obtained, with 94.05%, belonged to the Linear SVM model as a result of iris analysis. SVM was followed by ANN with

92.86%, NN with 89.29%, DT with 88.1%, and finally, the k-NN classifier with 86.9%. SVM also performed the best in the metrics of Specificity, Precision, and F1 criterion with values of 92.31%, 93.48%, and 94.51% respectively. In the Sensitivity metric, k-NN was the best classifier with 100%, while the ANN model achieved the highest success with an AUC value of 97.01%.

As a result of the analysis including iris and biodemographic data together, it was observed that the metric values increased. The accuracy metric increased to 95.24% in the SVM model. The SVM model also yielded the best results in Specificity, Precision, F1 criterion, and AUC metrics with values of 94.87%, 95.56%, 95.56%, and 98.12% respectively. In the Sensitivity metric, k-NN remained the best classifier with 100%.

This study introduces a new model that is developed and evaluated for CAD detection, a common cardiovascular condition. The proposed model is compared to existing models previously used for CAD detection. The comparison results indicate that the proposed model outperforms the existing models in terms of the success rate in CAD detection. These findings demonstrate the effectiveness and superiority of the proposed model in accurately detecting CAD, highlighting its comprehensive and successful structure, unlike previous works in this field.

Keywords: Iris, Biodemographic, Iridology, Coronary artery disease, Image processing, Machine learning.

ÖN SÖZ VE TEŞEKKÜR

Bu çalışmanın hazırlanmasında değerli katkılar sunan başta danışman hocam Doç. Dr. Çetin Kurnaz olmak üzere tezimin doktora tez izleme jürilerine teşekkürü bir borç bilirim. Doktora eğitimim süresince desteklerini esirgemeyen Arş. Gör. Nihal Genç'e, başta Dr. Öğr. Üyesi Ertan Aydın olmak üzere Giresun Üniversitesi Eğitim-Araştırma Hastanesi Kardiyoloji Polikliniği hekimlerine, Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü araştırma görevlilerine, mesai arkadaşlarıma ve her zaman yanımda olan sevgili aileme sonsuz teşekkürlerimi sunarım.

Ferdi ÖZBİLGİN

İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT	iv
ÖNSÖZ VE TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	ix
1. GİRİŞ	1
1.1. Tezin Katkıları	3
1.2. Tez İçeriği	4
2. GENEL BİLGİLER	5
2.1. Gözün Anatomisi	5
2.1.1. İris ve Yapısı	8
2.2. Kalbin Anatomisi	11
2.2.1. Kalp Hastalıkları	12
2.3. Koroner Arter Hastalığı	14
2.3.1. Epidemiyoloji	15
2.3.2. Risk Faktörleri	16
2.3.3. Hastalık Tanısı	18
2.4. İridoloji	20
2.4.1. Tanım ve Genel Bakış	20
2.4.2. Tarihçe	21
2.4.3. İris İşaretleri	23
3. LİTERATÜR ÖZETİ	25
3.1. İridoloji ile İlgili Çalışmalar	25
3.2. Kalp Hastalıkları Kapsamında İridolojinin Kullanıldığı Çalışmalar	27
4. MATERYAL VE YÖNTEM	30
4.1. Veri Toplama	30
4.1.1. Göz Görüntülerinin Elde Edilmesi	31
4.1.2. Biyodemografik Sağlık Profili Verileri	33
4.2. Görüntü Ön-İşleme	35
4.2.1. Gözbebeği ve İris Konumunun Belirlenmesi	35
4.2.2. Normalizasyon İşlemi	36
4.2.3. ROI'nin Tespiti	37
4.2.4. Görüntü İyileştirme	38
4.3. Öznitelik Çıkarma	39
4.3.1. Ayrık Dalgacık Dönüşümü	39
4.3.2. Birinci Dereceden İstatistiksel Analizler	41
4.3.3. Gri Seviye Eş-oluşum Matrisi (GLCM)	43
4.3.4. Gri Seviye Koşu Uzunluğu Matrisi (GLRLM)	49
4.4. Öznitelik Seçme İşlemi	51
4.5. Sınıflandırma	52
4.5.1. Naive Bayes (NB)	52
4.5.2. Karar Ağaçları (DT)	53
4.5.3. k-En Yakın Komşu (k-NN)	55
4.5.4. Destek Vektör Makineleri (SVM)	56

4.5.5. Yapay Sinir Ağları (ANN).....	58
4.6. Performans Değerlendirme.....	61
4.7. Önerilen Yöntem	65
5. BULGULAR VE TARTIŞMA.....	69
5.1. Verilere Ait İstatistiksel Bilgiler	69
5.2. Öznitelik Analizi	71
5.2.1. İris Öznitelikleri.....	71
5.2.2. Fizyolojik Öznitelikler.....	74
5.3. Naive Bayes Sınıflandırıcısına Ait Bulgular	75
5.4. Karar Ağaçları Sınıflandırıcısına Ait Bulgular.....	78
5.5. k-NN Sınıflandırıcısına Ait Bulgular	81
5.6. Destek Vektör Makineleri Sınıflandırıcısına Ait Bulgular.....	86
5.7. Yapay Sinir Ağları Sınıflandırıcısına Ait Bulgular	90
5.8. İris Özniteliklerine Fizyolojik Parametrelerin Eklenmesi ile Performans Ölçümleri.....	94
6. SONUÇLAR VE ÖNERİLER.....	98
6.1. Sonuçlar.....	98
6.2. Öneriler.....	99
KAYNAKLAR	100

SİMGELER VE KISALTMALAR

ANN	: Artificial Neural Networks
AUC	: Area Under The ROC Curve, ROC Eğrisinin Altında Kalan Alan
AV	: Atriyovenriküler
CHF	: Congestive Heart Failure, Konjestif Kalp Yetmezliği
DT	: Decision Trees
DVM	: Destek Vektör Makineleri
DWT	: Discrete Wavelet Transform, Ayrık Dalgacık Dönüşümü
EKG	: Elektrokardiyogram
FPR	: False Positive Rate, Yanlış Pozitif Oranı
FP	: False Positive, Yanlış Pozitif
FN	: False Negative, Yanlış Negatif
GLCM	: Gray Level Co-Occurrence Matrices, Gri Seviye Eş-Oluşum Matrisi
GLRLM	: Gray Level Run Length Matrix, Gri Seviye Koşu Uzunluğu Matrisi
HDL	: High-Density Lipoprotein, Yüksek Yoğunluklu Lipoprotein
HH	: High-High, Yüksek-Yüksek
HL	: High-Low, Yüksek-Düşük
İDO	: İntegral-Diferansiyel Operatörü
KA	: Karar Ağaçları
KAH	: Koroner Arter Hastalığı
k-NN	: k-Nearest Neighbor, k-En Yakın Komşu
LH	: Low-High, Düşük-Yüksek
LL	: Low-Low, Düşük-Düşük
LDL	: Low-Density Lipoprotein, Düşük Yoğunluklu Lipoprotein
MI	: Myocardial Infarction, Miyokard Enfarktüsü
NB	: Naive Bayes
PCA	: Principal components analysis, Temel Bileşenler Analizi
RF	: Random Forest
ROC	: Receiver Operating Characteristic Curve
ROI	: Region of Interest
SA	: Sinoatriyal
SVM	: Support Vector Machines

TEKHARF	: Türk Eriřkinlerindeki Kalp Hastalıęı ve Risk Faktörleri
TN	: True Negative Doğru Negatif
TP	: True Positive, Doğru Pozitif
TPR	: True Positive Rate, Doğru Pozitif Oranı
TÜİK	: Türkiye İstatistik Kurumu
WHO	: World Health Organization, Dünya Sağlık Örgütü
YSA	: Yapay Sinir Ağları



ŞEKİLLER DİZİNİ

Şekil 2.1. Gözün anatomisi (Anonim, 2022a).....	5
Şekil 2.2. Gözün önden görünümü (Maciejewicz, 2019).....	9
Şekil 2.3. İris kaslarının farklı ışık seviyelerindeki hareketi (Anonym, 2022a).....	9
Şekil 2.4. İrisin yüzey deseni (Basak, 2019).....	10
Şekil 2.5. İrisin enine kesiti (Basak, 2019)	10
Şekil 2.6. Kalbin genel anatomik yapısı (Gürsürer, 2023).....	11
Şekil 2.7. Koroner arter damarları (O. Özdemir, 2017).....	14
Şekil 2.8. Ateroskleroz basamakları (Gerçekoğlu, 2017)	15
Şekil 2.9. İris bölümlenmesi (Pau, 2019).....	22
Şekil 2.10. İris haritası (Health, 2023)	23
Şekil 2.11. İris deseninde a) bükülme, b) halka oluşması, c) gerilme, d) siyah nokta, e) beyaz nokta, f) hem siyah hem beyaz nokta belirtilerine örnekler (Lodin ve Demea, 2009)	24
Şekil 4.1. Çalışmadaki sürece ait genel akış şeması	30
Şekil 4.2. Çalışmadaki (a) Görüntü alma sistemi (b) Örnek bir göz görüntüsü alınma aşaması.....	31
Şekil 4.3. KAH grubundaki gönüllülere ait göz görüntüleri.....	33
Şekil 4.4. Kontrol grubundaki gönüllülere ait göz görüntüleri	33
Şekil 4.5. Göz görüntüsü ön-işleme süreci aşamaları	35
Şekil 4.6. İris normalizasyonu.....	37
Şekil 4.7. Sol iristeki kalp bölgesinin konumu	38
Şekil 4.8. Örnek bir ROI bölgesi görüntüsü için (a) Orijinal görüntü ve histogramı (b) Histogramı eşitlemiş görüntü ve histogramı (c) CLAHE yöntemi sonucundaki görüntü ve histogramı	39
Şekil 4.9. 1-Seviye DWT ayrışması.....	40
Şekil 4.10. n-Seviye DWT ayrışması.....	41
Şekil 4.11. Komşu piksel analizi için yön bilgisi.....	43
Şekil 4.12. Bir piksel komşuluk ve 0° yönlü GLCM matrisinin oluşturulması	43
Şekil 4.13. 0° yönlü GLRLM matrisinin oluşturulması	49
Şekil 4.14. Örnek bir karar ağacı	54
Şekil 4.15. KNN sınıflandırıcısı için iki farklı sınıfa ait örnek bir veri dağılımı (José, 2018)	55
Şekil 4.16. İki sınıflı örnek bir veri grubu için hiperdüzlem ve destek vektörlerinin gösterimi	57
Şekil 4.17. Tek nöronlu bir ANN mimarisi.....	59
Şekil 4.18. Çok katmanlı bir ANN mimarisi (Zaloğlu, 2015)	59

Şekil 4.19. K-katlı çapraz doğrulama gösterimi.....	62
Şekil 4.20. İki farklı modele ait örnek ROC eğrileri.....	65
Şekil 4.21. Önerilen KAH tahmini süreci	66
Şekil 4.22. İris öz niteliklerinin çıkarılma sürecine ait akış süreci	66
Şekil 5.1. Gönüllülerin yaşlarına göre sağlık durumu bilgileri.....	70
Şekil 5.2. Gönüllülerin yaşlarına göre cinsiyet bilgileri	71
Şekil 5.3. 1 seviye DWT dönüşümü sonucunda elde edilen öz nitelikler ve korelasyon katsayıları	72
Şekil 5.4. 2 seviye DWT dönüşümü sonucunda elde edilen öz nitelikler ve korelasyon katsayıları	72
Şekil 5.5. NB sınıflandırıcıları için ROC eğrileri	78
Şekil 5.6. DT sınıflandırıcıları için ROC eğrileri.....	81
Şekil 5.7. k-NN sınıflandırıcıları için ROC eğrileri.....	86
Şekil 5.8. SVM sınıflandırıcıları için ROC eğrileri	90
Şekil 5.9. ANN sınıflandırıcıları için ROC eğrileri	94

TABLolar DİZİNİ

Tablo 4.1. Verilerin alındığı fotoğraf makinesi teknik özellikleri.	32
Tablo 4.2. Fotoğraf makinesindeki lense ait teknik özellikler	32
Tablo 4.3. Biyodemografik sağlık profili öznitelikleri ve veri tipleri.....	34
Tablo 4.4. İki sınıflı bir karışıklık matrisi	62
Tablo 4.5. Çalışmada kullanılan sınıflandırıcı model isimleri ve parametreleri.....	68
Tablo 5.1. Gönüllülere ait yaş ve cinsiyete göre istatistiksel bilgiler	70
Tablo 5.2. ReliefF yöntemine göre en yüksek rank değerine sahip öznitelikler.....	74
Tablo 5.3. Fizyolojik parametrelere ait istatistiksel bilgiler ve korelasyon katsayıları (n=281).....	75
Tablo 5.4. NB Model I bulguları.....	76
Tablo 5.5. NB Model II bulguları	77
Tablo 5.6. DT Model I bulguları.....	79
Tablo 5.7. DT Model II bulguları.....	79
Tablo 5.8. DT Model III bulguları	80
Tablo 5.9. k-NN Model I bulguları	82
Tablo 5.10. k-NN Model II bulguları.....	82
Tablo 5.11. k-NN Model III bulguları	83
Tablo 5.12. k-NN Model IV bulguları	84
Tablo 5.13. k-NN Model V bulguları.....	84
Tablo 5.14. k-NN Model VI bulguları	85
Tablo 5.15. SVM Model I bulguları.....	87
Tablo 5.16. SVM Model II bulguları	87
Tablo 5.17. SVM Model III bulguları.....	88
Tablo 5.18. SVM Model IV bulguları.....	88
Tablo 5.19. SVM Model V bulguları	89
Tablo 5.20. SVM Model VI bulguları.....	89
Tablo 5.21. ANN Model I bulguları.....	91
Tablo 5.22. ANN Model II bulguları	91
Tablo 5.23. ANN Model III bulguları.....	92
Tablo 5.24. ANN Model IV bulguları.....	93
Tablo 5.25. ANN Model V bulguları	93
Tablo 5.26. Sınıflandırıcıların karşılaştırmalı analizi	94
Tablo 5.27. Fizyolojik özniteliklerin eklenmesi sonucu oluşan metrik değerleri.....	95
Tablo 5.28. Mevcut çalışmalarla karşılaştırma tablosu.....	96

1. GİRİŞ

Koroner Arter Hastalığı (KAH), kalp kaslarını besleyen koroner arterlerdeki kan akışının azalması veya tamamen kesilmesi sonucu oluşan bir kardiyovasküler hastalıktır. Kardiyovasküler hastalıklar nedeniyle her yıl yaklaşık olarak 17.9 milyon kişi hayatını kaybetmekte ve bu da küresel çaptaki ölümlerin %30'unu oluşturmaktadır (Malakar vd., 2019). Amerikan Kalp Derneği, önlem alınmadığı takdirde ölümlerin 2030 yılında 22 milyona yaklaşacağını öngörmektedir (Benjamin vd., 2019). Türkiye İstatistik Kurumu (TÜİK) verilerine göre de Türkiye'deki ölümlerin yaklaşık %37'si kardiyovasküler hastalıklar nedeniyle gerçekleşmektedir (TÜİK, 2019). KAH ise bu hastalıklar arasında en yüksek mortalite oranına sahip olanıdır (Nowbar vd., 2019).

KAH tanısı koymak için bir dizi laboratuvar testi ve görüntüleme yöntemi kullanılmaktadır. Hastanın şikayetleri, aile öyküsü, risk faktörleri ve fizik muayene bulgularının sonuçları değerlendirilerek tanı konulur. KAH tanısı için kan testleri, elektrokardiyografi (EKG), efor testleri, Holter testleri ve ekokardiyografi (EKO) yaygın olarak kullanılan testlerdir. KAH'lı hastalarda semptomların başlangıcı, spesifik olmayan basit göğüs ağrısından doğrudan kalp krizine ve hatta ölüme kadar değişebilir. İhmal edilen bulgular kalp krizine yol açabilir; hasta ölmese bile kalp kasında ciddi hasar meydana gelebilir. Bu nedenle KAH'da erken tanı çok önemlidir (Alizadehsani vd., 2016; Ghiasi vd., 2020).

Bilgisayar destekli sistemler ile hastalık teşhisi son yıllarda araştırmacılar tarafından sıklıkla çalışılan konular arasındadır. Sistem içinde barındırmış olduğu makine öğrenmesi ve derin öğrenme gibi yapay zeka desteği teşhis süreçlerinde yüksek doğruluk ve verimlilik sağlamaktadır. Geliştirilen sistemler ile büyük miktarda veriyi insanlardan daha hızlı ve doğru bir şekilde analiz edebilir. Tıbbi kayıtları, laboratuvar sonuçlarını ve görüntüleme taramalarını işleyerek uzman klinisyenler tarafından kolayca fark edilemeyebilecek kalıpları ve korelasyonları belirleyebilirler. Bu sistemler, geniş tıbbi bilgi ve veri tabanlarına erişerek klinisyenlerin daha geniş bir olasılık yelpazesini değerlendirmesine ve daha bilinçli kararlar almasına yardımcı olabilir. Bu da teşhis doğruluğunu ve verimliliğini artırabildiği gibi hata riskini de azaltabilmektedir. Ayrıca uzak veya yetersiz hizmet alan bölgelerde, bilgisayar

destekli sistemler hastaları semptomlarını uzaktan değerlendirebilen ve tıbbi verileri gözden geçirebilen sağlık uzmanlarına bağlayarak teşhisi kolaylaştırabilir.

Son yıllarda birçok hastalığın teşhis edilmesinde iris kullanılmaya başlamıştır. Samant ve Agarwal tarafından yürütülen bir çalışmada, pankreas bölgesindeki iris dokusunun analizine dayalı olarak dalgacık dönüşümü temelli diyabet teşhisi için çeşitli makine öğrenimi teknikleri kullanılmıştır. Benzer şekilde, son yıllarda araştırmacılar diyabet teşhisi için çok sayıda model önermiştir (Bansal vd., 2015; Önal vd., 2023). Literatürde ayrıca iridolojinin böbrek hastalıklarının teşhisinde (Muzamil, vd., 2020), beyin rahatsızlıklarında (Hernández vd., 2018) ve kan dolaşımındaki kolesterol seviyelerinin değerlendirilmesinde (Kurnaz ve Gül, 2018; Özbilgin ve Kurnaz, 2022; Özbilgin, 2019; Ramlee ve Ranjit, 2009) kullanımına ilişkin çalışmalar da yer almaktadır. Bu araştırmalar toplu olarak, iridolojinin hastalıkların erken teşhisi için non-invaziv bir yaklaşım olarak etkinliğinin altını çizmektedir. Bununla birlikte, kalp rahatsızlıklarının zamanında teşhisi için iris analizinin kullanılmasına ilişkin bir araştırma boşluğu bulunmaktadır. Dünya çapındaki araştırmacılar, vücut fonksiyonları için çok önemli bir organ olan kalple ilişkili iris görüntülerinden yararlanarak non-invaziv görüntü işleme ve yapay zeka güdümlü tıbbi analiz konusunda önemli adımlar atmıştır. (Gunawan vd., 2022), KAH tespiti için Destek Vektör Makinesi (Support Vector Machines, SVM) sınıflandırıcı ve Gri Seviyeli Eş-oluşum Matrisi (Gray Level Co-. Occurence Matrix, GLCM) özelliklerini kullanan bir metodoloji önermiştir. Çalışmada, test verileri üzerinde SVM sınıflandırıcısı kullanılarak %91 tespit doğruluğu elde edilmiştir. (Putra vd., 2018) kardiyak sorunlarını belirlemek için bir iris analiz sistemi geliştirmiştir. Yaklaşımları, özellik çıkarma için Temel Bileşenler Analizi (Principal Component Analysis, PCA) ve GLCM tekniklerini ve sınıflandırma için sinir ağlarını içermektedir. GLCM ve PCA özelliklerini kullanarak sırasıyla %77,5 ve %90 sınıflandırma doğruluğu elde etmişlerdir. (Permatasari vd., 2016) PCA özellik çıkarma yöntemini bir SVM sınıflandırıcıyla birlikte kullanarak maksimum %80 doğruluk elde etmiştir. (Kusuma vd., 2018) mobil tabanlı bir sistem aracılığıyla yakalanan iris görüntülerini kullanarak kardiyak anormallikleri tespit etmek için bir model önermiştir. Siyah ve beyaz formata dönüştürülen analiz edilen bölgedeki siyah ve beyaz piksellerin oranını ayırt edici bir özellik olarak kullanmışlardır. Eşikleme yöntemini kullanarak test verileri için %83,3'lük bir doğruluk performansı elde etmiştir. Özbilgin ve arkadaşları, iris görüntülerini kullanarak KAH tahmini üzerine iki ayrı çalışma yürütmüştür. Toplam 198 gönüllünün katıldığı ilk çalışmada, iris

görüntüleri üzerinde Yerel İkili Örüntüler (Local Binary Patterns, LBP) özellik çıkarımı gerçekleştirilmiş ve ANN kullanılarak %91,5 oranında sınıflandırma başarıları elde edilmiştir (Özbilgin ve Kurnaz, 2023). İkinci çalışmada, dalgacık dönüşümüne dayalı istatistiksel ve dokusal özellikler çıkarılmış ve farklı makine öğrenmesi algoritmaları kullanılarak sınıflandırma gerçekleştirilmiştir. En yüksek sınıflandırma doğruluğu %93 ile SVM sınıflandırıcısı kullanılarak elde edilmiştir (Özbilgin vd., 2023). Bu çalışmalar, KAH teşhisinde iridolojinin potansiyelini etkili bir şekilde vurgulamaktadır.

Kalp hastalıklarının erken teşhisi için iris analizine ilişkin mevcut literatür farklı metodolojiler sergilemekle birlikte, farklı kalp rahatsızlıklarının kapsamlı bir değerlendirmesinden yoksundur. Çalışmalar genellikle iris konumunun belirlenmesi, dikdörtgen dönüşümler, analiz bölgesinin belirlenmesi, özellik çıkarımı ve sınıflandırmayı içeren standart bir prosedür izlerken, analiz bölgesinin belirlenmesinden sonra önemli farklılıklar vardır. Bazı çalışmalar analiz bölgesini alt bölümlere ayırmak ve diyabeti teşhis etmek için dalgacık dönüşümlerini başarıyla kullanmış olsa da, bu yöntemin kalp hastalıklarını tespit etmede uygulanabilirliği henüz keşfedilmemiştir.

Bu çalışmanın temel odak noktası, iris görüntüleri ve biyodemografik verilerin analizi yoluyla KAH'nın invazif olmayan tespiti. Bu araştırma, daha fazla öznetelik çıkarmak, daha fazla sayıda öznetelik kullanmak ve daha fazla sınıflandırıcı kullanmak için dalgacık dönüşümlerini dahil ederek, önceki çalışmalara kıyasla daha kapsamlı ve güvenilir sonuçlar elde etmektedir.

1.1. Tezin Katkıları

Önerilen KAH tahmin çalışmasının literatüre katkıları aşağıdaki gibi sıralanabilir;

- İris görüntüleri kullanılarak KAH'nın non-invaziv tespiti için yeni bir teşhis yaklaşımı önerilmiştir.
- Dalgacık dönüşümü temelli ReliefF özellik seçimi yöntemi tanıtılmış ve istatistiksel, GLCM ve Gri Seviye Koşu Uzunluğu Matrisi (Gray Level Run Length Matrix, GLRLM) özelliklerini içeren 272 öznetelik elde edilmiştir.
- İris parametrelerine ek olarak hastalardan elde edilen 14 adet biyodemografik veri de analize dahil edilmiştir.

- Naive Bayes (NB), Karar Ağaçları (Decision Trees, DT), k-En Yakın Komşu (k-Nearest Neighbors, k-NN), Destek Vektör Makineleri (Support Vector Machine, SVM) ve Yapay Sinir Ağları (Artificial Neural Networks, ANN) gibi farklı makine öğrenmesi sınıflandırıcıları arasında bir karşılaştırma yapılmış ve en iyi performans gösteren sınıflandırıcı belirlenmiştir.
- Önerilen model mevcut modellerle karşılaştırılmış ve KAH tespitinde daha başarılı olduğu görülmüştür.


1.2. Tez İçeriği

Bu tez beş bölüm halinde organize edilmiştir. Bölüm 1, tez çalışmasında ele alınan problemin ana hatlarını çizen ve önerilen yöntemin ele almayı amaçladığı potansiyel sorunları tartışan bir giriş niteliğindedir. Bölüm 2, önerilen yöntemin temelini oluşturan genel bilgiler kısmını oluşturmaktadır. Bu bölümde, gözün anatomisi ve iris yapısı, kalbin anatomisi ve Koroner Arter Hastalığı ve son olarak da iridoloji hakkında genel bilgiler yer almaktadır. Bölüm 3, metodoloji ile ilgili önceki çalışmalara odaklanarak alandaki ilgili çalışmaları incelemektedir. Bu çalışmalarda benzer sorunlara nasıl yaklaşıldığı incelenmekte ve elde edilen sonuçlar verilmektedir. Bölüm 4, çalışma süresince kullanılan materyaller ve yöntemler detaylı olarak açıklanmaktadır. Kullanılan yöntemlerin formülasyonu, analizlerin uygulanması, öznitelik çıkarma aşamaları ve sınıflandırma için kullanılan makine öğrenmesi tekniklerinin uygulanması açıklanmaktadır. Bölüm 5, analizlerin elde edilen sonuçlarına odaklanmakta ve kapsamlı bir tartışma içermektedir. Aynı zamanda bulguların alandaki diğer ilgili çalışmalarla karşılaştırılmasını barındırmaktadır. Son olarak, Bölüm 6'da, araştırmayı özetleyen bir sonuç sunulmakta ve önerilen yöntemin geliştirilmesi için gelecekteki yönleri belirtilmektedir.

2. GENEL BİLGİLER

2.1. Gözün Anatomisi

Göz, kemiklerden oluşan Orbita isimli göz çukurunda yer alan, yaklaşık 22-26 mm çapında, yaklaşık ağırlığı 7.5 g, yaklaşık hacmi 6.5 ml olan ve görme olayına yardımcı küresel bir organdır (Cassel, 2021; Forrester vd., 2020). İnsan gözünün anatomisi Şekil 2.1’de verildiği gibidir. Göze gelen ışık; kornea, göz bebeği ve göz merceğinden geçerek gözün arka kısmındaki retinada toplanır. Retinada oluşan görüntü optik sinir ile beyine taşınarak görme algısı oluşur.



Şekil 2.1. Gözün anatomisi (Anonim, 2022a)

Göz üç tabakadan oluşmaktadır (Senior, 2010). Bu katmanlar gözün iç saydam yapısını çevreler. Bunlar;

1. Dış katman
 - Kornea
 - Sklera
2. Orta katman (Uvea)
 - Siliyer Cisim
 - İris
 - Koroid
3. İç katman

- Retina

Kornea: Gözün en ön kısmında yer alan, iris, gözbebeği ve ön kamarayı kaplayan saydam bir tabakadır. %78'lik su içeriği ile gelen ışığın odaklanmasına yardımcı olmaktadır. Kornea, sırasıyla yaklaşık olarak 11 ve 12 mm'lik dikey ve yatay bir çapa sahip elips şeklindedir. Korneanın ana işlevi ışığı kırmak veya bükmeektir. Kornea, göze giren ışığın çoğunun odaklanmasından sorumludur. Kornea proteinlerden ve hücrelerden oluşur. İnsan vücudundaki çoğu dokudan farklı olarak kan damarı içermez. Kan damarları korneayı bulanıklaştırabilir, bu da ışığın düzgün bir şekilde kırılmasını engelleyebilir ve görüşü olumsuz etkileyebilir. Korneada besin sağlayan kan damarları bulunmadığından, ön kamaradaki gözyaşı ve aköz hümör korneaya besin sağlar (Mayya vd., 2021; Ng vd., 2012).

Kornea; kornea epitel, Bowman zarı, kornea stroması, Desme zarı ve kornea endoteli olmak üzere beş katmandan oluşmaktadır (Koplin vd., 2020). Küçük sıyrıklardan kendini hızla tamir etme eğilimindedir. Ancak daha derin sıyrıklar korneada izlere neden olabilir ve bu da korneanın saydamlığını kaybetmesine neden olarak görme bozukluğuna neden olabilir (Wilson, 2020).

Sklera (Sert tabaka): Göze dışarıdan bakıldığında beyaz renkli görünen kısımdır. Sklera sıkı örülmüş kollajen liflerinden yapılmıştır ve oldukça serttir. Bu nedenle skleraya, sert tabaka adı da verilmektedir. Göz çevresinde yer alan altı adet kas bağlantısı ile gözün hareketini kontrol etmektedir. Sklera alttaki koroid ve retina gibi görmemiz açısından son derece önemli yapıları koruma görevini üstlenmektedir. Gözün en arkasında optik sinir ile birbirine bağlıdır (Acharya vd., 2008; Pradeep vd., 2019).

Siliyer Cisim: İrisin arkasında 5-6 mm genişliğinde disk şeklinde bir doku halkasıdır. Siliyer cisim görüşümüz açısından önemli bir rol oynar. Aköz hümör sıvısı üretir ve lensin yerleşiminden sorumlu siliyer kasları içerir. Siliyer kasının kasılıp gevşemesi lensin kalınlığını değiştirebilir. Bu da hem yakın hem de uzak mesafelerdeki nesnelere odaklanılabilmesini sağlar (Armstrong ve Cubbidge, 2019; Justice vd., 2011).

Koroid: Sklera ve retina arasında bulunan gözün vasküler ve bağ dokusu tabakasıdır. Koroidin hemen iç kısmında bulunan retinanın kanlanması ve beslenmesinden sorumludur. Gözdeki toplam kan akışının %85'ini oluşturan koroid dolaşımı, nispeten

düşük oksijen içeriğine sahip yüksek akışlı bir sistemdir. Toplam koroidal kan temini, retina beslenmesi ihtiyacını fazlasıyla aşmaktadır ve aynı zamanda retinanın aşırı ısınmasını önlemek için bir ısı değişim mekanizması olarak da hizmet etmektedir. (Boileau ve Gilmour, 2012; Ehrlich vd., 2017; Lambert-Cheatham vd., 2021).

Retina: Gözün iç kısmını kaplayan ince bir sinir hücresi tabakasıdır. Optik sinirin yanında bulunur. Retinanın görevi, merceğin odakladığı ışığı almak, ışığı sinirsel sinyallere dönüştürmek ve bu sinyalleri görsel tanıma için beyne göndermektir. Retina, ışığı bir fotoreseptör hücre tabakasından geçirir. Bunlar ışığa duyarlı hücreler olup renk ve ışık yoğunluğu gibi nitelikleri tespit etmekten sorumludur. Retina, fotoreseptör hücreler tarafından toplanan bilgileri işler ve bu bilgiyi optik sinir yoluyla beyne gönderir. Temel olarak, retina odaklanmış ışıktan gelen bir resmi işler ve resmin ne olduğuna karar vermek için beyne gönderir.

Görme yetisi için hayati rolü olan retinanın zarar görmesi kalıcı körlüğe neden olabilir. Retinanın normal konumundan anormal şekilde ayrıldığı retina dekolmanı gibi durumlar, retinanın ışığı almasını veya işlemesini engelleyebilir. Söz konusu durum, beynin bu bilgiyi almasını engelleyerek körlüğe yol açmaktadır (Acharya vd., 2008; Marchesi vd., 2021; Shao ve Wong, 2020).

Lens: Kornea ile birlikte retinaya odaklanmak için ışığın kırılmasına yardımcı olan gözdeki şeffaf, elipsoid ve bikonveks şeklindeki bir yapıdır. Lens; odak değiştirdikçe şekli ve boyutu değişse de, yetişkinlerde yaklaşık 0 mm (ön-arka çap) ve 4 mm (üst-alt çap) boyutlarındadır. Lens, şeklini değiştirerek gözün odak mesafesinin değişmesine neden olur ve bu nedenle retinada keskin görüntüler elde edilmesine yardımcı olur. Lens, lens kapsülü, lens epiteli ve lens liflerinden oluşur. Lens kapsülü, lensin pürüzsüz, şeffaf en dış tabakası iken, mercek lifleri lensin kütlesini oluşturan uzun, ince, şeffaf hücrelerdir. Lens epiteli bu ikisi arasında yer alır ve lensin stabil çalışmasından sorumludur. (Acharya vd., 2008; Erol vd., 2018).

Vitreus: Gözün içini dolduran ve yaklaşık %99'u su olan neredeyse saydam ve jel şeklindeki sıvıdır. Geriye kalan %1'lik kısım ise vitreus'un jelatinimsi bir kıvama sahip olmasına neden olan kolajen ve hyaluronik asittir. Vitreus, gözün şeklini korumanın yanı sıra göze gelen darbeleri emmeye yardımcı olur ve retinayı gözün arka duvarına düzgün şekilde bağlı tutar. Işık retinaya giderken vitreustan geçer. Gözde

uçuşan cisimler görmek vitreusun içinde bulunan küçük birikintilerdir (Cassel, 2021; Yadav vd., 2021).


Optik Sinir: Gözün arka kısmında yer alır. İkinci kranial sinir veya kranial sinir II olarak da adlandırılır. Birkaç çift kranial sinirden ikincisidir. Optik sinir, ganglionik hücrelerden veya sinir hücrelerinden oluşur. Kör nokta, retinanın optik sinire bağlandığı kısmında, özel ışığa duyarlı hücrelerin veya fotoreseptörlerin olmadığından kaynaklanır. Optik sinirin görevi, elektriksel uyarılar yoluyla retinadan gelen görsel bilgiyi beynin görme merkezlerine aktarmaktır. Bir milyondan fazla sinir lifine sahiptir. Eğer sinirin bütününde veya bir kısmında iltihap söz konusu ise fonksiyon tam gerçekleşmez ve görmede problem yaşanır (Sevastyanov, 2019; Wang vd., 2020).

Sarı Nokta: Yüksek pigmentli sarımsı oval şekilli bir nokta olarak tanımlanan insan gözü retinasının orta kısmının yakınında bulunur. Yaklaşık olarak 5 mm çapındadır ve yoğun olarak ışığa duyarlı fotoreseptör hücreleri barındırır. Bu hücreler; sarı noktanın merkezi görüşün kontrolünde olmasını ve ayrıntıları ayırt etmesini sağlar. Parlak ışıkta daha keskin bir görüş sağlar (Voigt vd., 2021; Yu vd., 2020).

Ön ve Arka Kamara: Ön kamara, gözün iris ve kornea arasındaki ön kısmıdır. Arka kamara ise iris ve lens arasında yer almaktadır. Ön kamara ve arka kamara aköz hümör adı verilen sıvı ile doludur. İki kamara birbirleri ile gözbebeği aracılığıyla ilişki halindedir. Arka kamarada üretilen aköz hümör gözbebeği yoluyla ön kamaraya geçer. Her iki kamarada da olan aköz hümör lensi ve korneayı besler ve göz içi basıncını oluşturur. Lens ve korneada kan akışı olmadığı için, aköz hümör kanın besinleri bu yapılara taşıma işini gerçekleştirir (Ahmad vd., 2018; Boughton vd., 2020).


2.1.1. İris ve Yapısı

İris, korneanın arkasında, göz merceğinin ve siliyer cismin önünde gözbebeğini çevreleyen kaslardan oluşan daire biçimindeki renkli kısma verilen isimdir. Şekil 2.2'de İris önden görülen göz görselinde görülmektedir. Kalınlığı 0,4-0,6 mm, çapı 11-14 mm kadardır (Basak, 2019; Malkoç, 2006; Ramzy, 2001).




Şekil 2.2. Gözün önden görünümü (Maciejewicz, 2019)

İris'in merkezinde 1-8 mm arasında değişen çapta yer alan açıklığa gözbebeği denir (Gökmen, 2003). Temel olarak iris kasılıp gevşeyerek gözbebeği boyutunu değiştirmektedir. Bu sayede değişik ışık miktarlı ortamlarda göze ne kadar ışığın girdiğini kontrol etmektedir. Şekil 2.3'te iris kaslarının ışık seviyelerine göre hareketi yer almaktadır. İriste, gözbebeğinin boyutunu ayarlayan iki adet kas mevcuttur. Bunlar Sfinkter pupilla ve Dilatatör pupilla kaslarıdır. Dilatatör pupilla gözbebeğini daha geniş açar, Sfinkter pupilla ise küçültür. Parlak ışıkta Sfinkter pupilla kasılır, Dilatatör pupilla gevşer ve gözbebeği küçülür. Az ışıkta ise Dilatatör pupilla kasılır, Sfinkter pupilla gevşer ve gözbebeği büyür (Abidin, 2021).




Şekil 2.3. İris kaslarının farklı ışık seviyelerindeki hareketi (Anonymous, 2022a)

Şekil 2.4'te irisin yüzey deseni yer almaktadır. İrisin yüzeyi siliyer bölge (ciliary zone) ve gözbebeği bölgesi (pupillary zone) olmak üzere iki bölgeye ayrılır. Bu iki bölge arasındaki sınıra yaka (collarette) denir. Siliyer bölgede sırt (ridge), kript (crypt) ve ben (mole) gibi yapılar yer almaktadır ancak gözbebeği bölgesinin nispeten daha düzdür (Iovino vd., 2021).



Şekil 2.4. İrisin yüzey deseni (Basak, 2019)

Şekil 2.5'te irisin enine kesiti yer almaktadır. İris karmaşık histolojik yapıya sahiptir. İriste önden arkaya doğru beş katman yer almaktadır. Bu katmanlar sırasıyla; endotel, stroma, kas lifleri, arka membran (ön epitel) ve arka pigment epitelidir. *Ön Endotel*, kornea endotelinin devamıdır. *Stroma*, iris çemberini oluşturan sinirler, düz kaslar ve radyal kan damarları ile bağ dokusundan oluşur. *Kas lifleri*, gözbebeği boyutunu ayarlayan Sfinkter pupilla ve Dilatör pupilla kaslarını içerir. *Arka membran* ve *arka pigment epiteli* ise pigmentlidirler ve gelişimsel olarak retinadan türetilmiştir. Ön membran yassı hücrelerden, arka pigment epiteli de küboidal hücrelerden oluşur (Moazed, 2020).




Şekil 2.5. İrisin enine kesiti (Basak, 2019)

Büyük oranda embriyonun gelişimine bağlı olan ve genetik oluşumlardan çok az etkilenen iris, kişinin yaşamı boyunca değişmemesi nedeniyle de biyometrik tanıma sistemlerinde sıklıkla kullanılmaktadır. DNA yapıları aynı olmasına rağmen tek yumurta ikizlerinin ve hatta kişinin kendi sağ ve sol irisleri bile birbirinden farklıdır. 400 farklı karakteristik özelliğe sahip iriste milimetre karedeki iris deseninin yoğunluğu 3,4 bittir ve bu da aynı iris yapısına rastlama oranını $(0.1)^{-78}$ gibi çok düşük bir sayı yapmaktadır (Gasson vd., 2005; Szweczyk vd., 2002). İris biyometrik

özelliğinin yanı sıra iridoloji bilimi ile sağlık teşhisi amaçlı da kullanılmaktadır (Sathyapriya vd., 2020).

2.2. Kalbin Anatomisi

Orta göğüs kemiğinin hemen arkasında ve iki akciğer arasında yer alan kalp tüm vücuda kan pompalayan bir kas organıdır (Peate, 2021). Kalbin ağırlığı 200 ile 425 gram arasındadır. Büyük bölümü kalbin kasılıp gevşemesinden sorumlu olan ve kalp kasını oluşturan Miyokard isimli tabakadan oluşmaktadır. Perikard adı verilen çift katmanlı bir zar kalbi kese gibi çevreler. Perikardın dış tabakası, kalbin ana kan damarlarının köklerini çevreleyerek omuriliğe, diyaframa ve vücudun diğer bölümlerine bağlanır. Perikardın iç tabakası kalp kasına bağlıdır. Bir sıvı kaplaması, iki zar tabakasını ayırarak, kalbin atarken hareket etmesine izin verir (Hassanabad vd., 2021). Kalp günde yaklaşık olarak durmaksızın 100.000 defa atar ve vücuda yaklaşık olarak 7500 litre kan pompalar. Şekil 2.6'daki kalbin genel anatomik yapısı görülmektedir. Kalp, dışta epikard, ortada miyokard ve içte endokard olmak üzere üç katmandan oluşmaktadır. Sahip olduğu dört odacık ve dört kapakçık ile damar ve iletim sisteminden oluşan bir yapıdır. Kalp, vücudun farklı bölgelerinden gelen kirli kanları alan ve üst kısımda yer alan sağ ve sol kulakçık (atriyum) ile temiz kanın gönderildiği ve alt kısımda yer alan sağ ve sol karıncık (ventrikül) bölümlerinden oluşmaktadır (Peate, 2021; Shetty ve Pavan, 2021).



Şekil 2.6. Kalbin genel anatomik yapısı (Gürsürer, 2023)

Kalp, vücuttaki tüm bölgelerden alınarak temizlenmesi gereken kanı toplama, toplanan kanı akciğerlere pompalama, akciğerlerden alınarak temizlenmiş kanı toplama ve son olarak temiz kanı tekrar vücudun tüm bölgelerine pompalama olmak üzere dört ana görevi yerine getirir. Kulakçıklar ve karıncıklar, birbirleriyle uyum içinde çalışmalarına rağmen bağımsız yapılar olarak yer alırlar. Kulakçıklar, karıncıklara, karıncıklar ise kulakçıklara elektriksel olarak tutunan, lifli ve iletken olmayan bir dokuya sahiptirler. İnce bir membranöz duvar olan interatriyal septum, sol atriyal odayı sağdan ayırırken, daha kalın bir kas duvarı olan interventriküler septum sol ventriküler odayı sağdan ayırır. Oksijen bakımından fakir (venöz) kan, üst ve alt vena kava adı verilen geniş damarlardan sağ atriya taşınır. Daha sonra, sağ atriya kasılmasıyla sağ ventrikülleri genişletilerek pompalama verimliliği en üst seviyeye çıkarılır ve venöz kan sağ ventriküllere aktarılır. Benzer şekilde, sol atriya ve sol ventrikül, pulmoner damar yoluyla akciğerlerden (oksijen ile zenginleştirilmiş) temiz kanı alarak, vücudun geri kalanına sirküle etmek için aorta pompalarlar (Farrell vd., 1992; Weinhaus ve Roberts, 2005).

2.2.1. Kalp Hastalıkları

Kalp hastalıkları, kalpte meydana gelen ve kalbi etkileyen herhangi bir bozukluğu kapsayan bir terimdir. Kardiyovasküler hastalık terimi ile eş anlamlı olarak kullanılan kalp hastalıkları aşağıdaki gibi sınıflandırılabilir:

Koroner arter hastalığı: Kalp kasının kan akışını sağlayan koroner arterlerin daralması veya tıkanması sonucu yetersiz olduğu durumda meydana gelmektedir. Göğüs ağrısı (angina), nefes darlığı, yorgunluk, çarpıntı veya kalp krizi gibi belirtiler ortaya çıkabilir (McCullough, 2007). Detaylı açıklama ayrı bir başlıkta verilmektedir.

Kalp kapak hastalıkları: Kalbin dört odasını birbirinden ayıran ve kan akışını düzenleyen kapaklarının daralması, yetersizlikleri veya tamamen kapalı olması nedeniyle kan akışı engellenmesi sonucu oluşmaktadır. Yaygın olarak görülen kalp kapak hastalıkları kapak darlığı ve kapak yetmezliğidir. Kapak darlığında (stenoz), bir kapak daraldığında, açılmak için yeterli derecede genişleyemez ve kan akışı kısıtlanır. Bu durum, kalbin pompalama gücünü etkileyebilir ve kalp kasının daha fazla çalışmasına neden olabilir. Kapak yetmezliğide (regürjitasyon) ise kapak tam olarak kapanmaz ve kanın geriye doğru kaçmasına izin verir. Bu durumda da kalp verimli bir

şekilde kan pompalayamaz. Nefes darlığı, göğüs ağrısı, yorgunluk, çarpıntı, bayılma hissi veya ödem gibi belirtiler içerebilmektedir (Coffey vd., 2016; Özdemir ve Çelik, 2018).

Kalp yetmezliği: Kalp kasının zayıflaması, sertleşmesi veya işlev bozukluğu nedeniyle kanı yeterli ve etkili miktarda vücuda pompalayamaması sonucunda ortaya çıkan kalp hastalığıdır. Kalp yetmezliği genellikle sol ventriküldeki sorunlardan kaynaklanır ve iki ana tipe ayrılır. Kalp kasının zayıflaması veya hasar görmesi sonucunda oluşan sistolik kalp yetmezliğinde, kalp normalden daha az kan pompalar. Bu durumda, kalbin pompalama gücü azalır ve vücut organları yeterli oksijen ve besin maddeleri alamaz. Diyastolik kalp yetmezliği, kalp kası sertleşir veya kalınlaşır, bu da kalbin dolma evresindeki kan miktarını kısıtlar. Kalp, normalden daha az kan alır ve pompalamadan önceki dolum evresinde zorlanır. Kalp yetmezliği, nefes darlığı, yorgunluk ve halsizlik, ödem ve göğüs ağrısı gibi semptomlara neden olmaktadır (Groenewegen vd., 2020).

Kalp ritmi bozuklukları: Kalbin elektriksel aktivitesindeki anormalliklerin oluşması sonucundaki kalp atışında düzensizliklerin oluşmasından dolayı meydana gelmektedir. Kalp atışının normalden daha yavaş olduğu Bradikardi’de kalp yetersiz miktarda kan pompalarken, Taşikardide kalp atışı hızı normalden daha hızlı olmakta ve hızlı bir şekilde kasılma olduğu için yeterli miktarda kan pompalanamamaktadır. Aritmi ise kalp atışlarındaki düzensizlik nedeniyle kalpten yeterli kan gönderilememektedir. Hastalık türüne göre nefes darlığı, halsizlik, baş dönmesi, çarpıntı, göğüs ağrısı ve bayılma gibi semptomlar açığa çıkabilmektedir (Serdyuk vd., 2021).

Konjenital kalp hastalıkları: Doğumdan önce veya doğumdan hemen sonra kalbin şeklinde, boyutunda veya işlevindeki anormalliklerden kaynaklanan hastalıklardır. Bu anormallikler, kalbin odaları, kapakları veya büyük damarları gibi bileşenlerindeki yapısal veya işlevsel bozukluklardan kaynaklanabilir (Williams vd., 2019).


Kardiyomiyopati: Kalbin kasılıp gevşemesinden sorumlu Miyokard isimli kalp kasının genişlemesi, kalınlaşması veya sertleşmesi gibi durumlarda meydana gelen kalp hastalığıdır. Bu hastalığın varlığı kalp yetmezliği ve aritmi olmak üzere çeşitli hastalıkların öncüsü olabilmektedir (Wexler vd., 2009).

Perikard hastalıkları: Kalbi dışarıdan saran ince bir zar tabakası olan Perikard'ın iltihaplanması, enfeksiyonu gibi durumların oluşması sonucunda oluşan kalp hastalıklarıdır (Dudzinski vd., 2012).

Vasküler hastalıklar: Vücuttaki kan akışı, oksijen ve besin maddelerinin taşınmasından sorumlu olan kan damarlarının yapısında veya fonksiyonunda bozuklukların oluşması nedeniyle ortaya çıkan kalp hastalıklarıdır (Adatia vd., 2010).


2.3. Koroner Arter Hastalığı

Kalp, atardamarlarda taşınan oksijenli kanı kullanarak çalışır. Kalp kası olan miyokard, kalbin kas hücrelerini oluşturur ve bu hücrelerin düzgün çalışabilmesi için sürekli bir oksijen ve besin kaynağına ihtiyaç duyar. İşte bu ihtiyacı karşılayan damarlar koroner arterlerdir. Koroner arterler, kalbin kendisine oksijenli kanı sağlayarak miyokard hücrelerinin çalışmasını sağlarlar. Şekil 2.7'de koroner arterler gösterilmektedir. Koroner arter damarları aorttan sağ koroner arter ve sol koroner arter olmak üzere iki dal halinde çıkarlar. Sol ana koroner arter, kalbin sol tarafına kan taşır. Sol ana koroner arter, sol ön inen arter ve sol sirkumfleks arter olmak üzere iki büyük dal halinde bölünür. Sol ön inen arter, kalbin ön tarafına doğru inerek miyokardın büyük bir bölümünü besler. Sol sirkumfleks arter ise kalbin sol yanına doğru dönerek miyokardın bir kısmını besler. Sağ koroner arter ise karıncıklar arasında kalan duvarın bir kısmını, sağ kalbi ve kalbin arka yüzünü besleyen dallara ayrılır (Loukas vd., 2009; Ogobuiro vd., 2022).



Şekil 2.7. Koroner arter damarları (Özdemir, 2017)

Koroner arter hastalığı (KAH), koroner arterlerin daralması veya tıkanması sonucunda oluşan bir kardiyovasküler hastalıktır. Bu daralma veya tıkanma, koroner arterlerin iç duvarlarında topluca plak olarak bilinen yağ birikintileri ve kolesterol gibi maddelerin birikmesi nedeniyle meydana gelir. Ateroskleroz (damar sertliği) adı verilen bir süreç olan plakların birikmesi, kalbe giden kan akışında azalmaya yol açarak göğüs ağrısı (anjina), nefes darlığı, kalp krizi ve hatta ölüme neden olabilir (Barton, 2013; Libby, 2021). Koroner arterlerin zaman içinde daralmasına ait örnek görüntü Şekil 2.8'deki gibidir.



Şekil 2.8. Ateroskleroz basamakları (Gerçekoğlu, 2017)

KAH'ın gelişimi ve ilerlemesi genetik, yaşam tarzı ve çevresel faktörler de dahil olmak üzere birçok faktörü içerir. KAH gelişme olasılığını artıran risk faktörleri arasında yaş, cinsiyet, aile öyküsü, sigara kullanımı, yüksek tansiyon, yüksek kolesterol seviyeleri, diyabet, fiziksel hareketsizlik, obezite ve stres yer almaktadır. Bu risk faktörleri arterlerin iç yüzeyine zarar vererek plak oluşumunu teşvik edebilir ve aterosklerozun ilerlemesine yol açabilir (Tetik ve Tanrıverdi, 2017).

2.3.1. Epidemiyoloji

Şu an dünya genelinde ve ülkemizde koroner arter hastalıkları önemli bir morbidite ve mortalite nedeni olarak görülmekte ve yaygınlığı hızla artmaktadır. Dünya Sağlık Örgütü'nün verilerine göre, 2020 yılında tüm ölümlerin %36'sının kardiyovasküler hastalıklara bağlı olacağı öngörülmüştür. Her yıl dünya genelinde yaklaşık 18 milyon kişi kardiyovasküler hastalıklara bağlı nedenlerden dolayı hayatını kaybetmektedir (WHO, 2021). Ülkemizde ise 2019 yılında ölüm vakalarının %36.8'ini dolaşım sistemi hastalıkları oluşturmuş ve bu hastalıkların %39.1'i iskemik kalp hastalığına bağlı olarak gerçekleşmiştir. Türkiye İstatistik Kurumu'na (TÜİK) göre,

kadınların yüzde 43.9'u, erkeklerin yüzde 36.4'ü bu nedenle yaşamını kaybetmektedir. (TÜİK, 2019). Türk Erişkinlerindeki Kalp Hastalığı ve Risk Faktörleri (TEKHARF) çalışması, Türkiye'de 2 milyon koroner arter hastası olduğunu ve yılda 160 bin kişinin koroner arter hastalığından hayatını kaybettiğini tahmin etmektedir. Ayrıca aynı çalışma, ülkemizde koroner arter hastalığı mortalite oranının, yaş grubu bazında erkeklerde binde 8.5, kadınlarda binde 4.5 olduğunu belirlemiştir. Ülkemizde, bölgesel olarak Karadeniz ve Marmara bölgelerinde koroner arter hastalığı görülme prevalansı diğer bölgelere kıyasla daha yüksekken, Akdeniz, Ege ve Güneydoğu Anadolu bölgelerinde ortalamanın altındadır. Koroner arter hastalığı mortalitesi açısından Türkiye, erkeklerde Avrupa ülkeleri arasında üçüncü sırada, kadınlarda ise birinci sırada yer almaktadır (Akman ve Civek, 2022; Onat, 2017).

2.3.2. Risk Faktörleri

KAH, değiştirilebilen ve değiştirilemeyen faktörler olmak üzere çeşitli risk faktörleri tarafından etkilenen çok faktörlü bir hastalıktır. Değiştirilebilen risk faktörleri, KAH riskini azaltmak için kontrol edilebilirken, değiştirilemeyen risk faktörleri modifiye edilememektedir.

Bir çalışma değiştirilebilir risk faktörlerinin KAH tanısında %60 üzerinde etkili olduğunu, değiştirilemez risk faktörlerinin ise nispeten düşük etkide olduğunu belirtmiştir (Pencina vd., 2019). Değiştirilemeyen risk faktörleri aşağıdaki gibidir.

Yaş: KAH prevalansı hem erkeklerde hem de kadınlarda 35 yaşından sonra artmaktadır. Erkeklerde ve kadınlarda 40 yaşından sonra yaşam boyu KAH gelişme riski sırasıyla %49 ve %32'dir (Sanchis-Gomar vd., 2016).

Cinsiyet: Erkekler menopoz öncesi kadınlara kıyasla daha yüksek KAH riskine sahiptir. Ancak menopozdan sonra kadınlardaki risk artar ve sonunda erkeklerinkiyle karşılaştırılabilir hale gelir (Görgel ve Çakıroğlu, 2007).

Etnik Köken: Afrikalı kökenliler, Hispanikler, Latinler ve Güneydoğu Asyalılar, KAH morbidite ve mortalite riski yüksek olan etnik gruplardır (Brown vd., 2020).

Aile Öyküsü: Ailesinde 50-55 yaşın altında erken kalp hastalığı öyküsü olan hastalarda KAH mortalite riski artmaktadır (Bachmann vd., 2012; Hajar, 2017)

Değiştirilebilen risk faktörleri değiştirilemez faktörlere göre daha etkisiz olsa da yine de önemli bir role sahiptir. Hastalar ilaç müdahalesi gibi gerekli önemi göstermesi halinde KAH görülme oranında azalma olacaktır (Berry vd., 2012; Pencina vd., 2019). Değiştirilebilen risk faktörleri aşağıdaki gibidir.

Sigara kullanımı: Gıda ve İlaç Dairesi (FDA), kardiyovasküler hastalık kaynaklı ölümlerin dünya genelinde yaklaşık beşte birini ve bu ölümlerin üçte birinin ise sigaradan kaynaklandığını tahmin etmektedir. 2015 yılında yapılan bir çalışmada, diyabetli hastalarda sigara içmenin koroner kalp hastalığı riskinde %51'lik bir artışa yol açtığını ortaya koymuştur (Pan vd., 2015). 2015 yılında yapılan başka bir çalışmada ise, 60 yaş üstü hastalar arasında sigara içmenin mevcut sigara içicilerinde kardiyovasküler hastalık riskinin iki katına, eski sigara içicilerinde ise %37'lik bir risk artışına neden olduğunu ortaya koymuştur (Mons vd., 2015). Düzenli olarak pasif içiciliğe maruz kalan sigara içmeyen kişilerde de koroner kalp hastalığı riski, maruz kalmayanlara kıyasla %25 ila %30 oranında artmaktadır (Japuntich vd., 2015).

Yüksek tansiyon: Hipertansiyon olarak da ifade edilen yüksek tansiyon, arter duvarına uyguladığı hem oksidatif hem de mekanik stres nedeniyle uzun zamandır kalp hastalıkları için önemli bir risk faktörüdür (Malakar vd., 2019). Değiştirilebilir risk faktörleri karşılaştırıldığında hipertansiyon ve sigara en fazla sayıda ölümden sorumlu tutulan risk faktörleri olmuştur (Danaei vd., 2009).

Yüksek kolesterol seviyeleri: Yüksek LDL (kötü) kolesterol ve trigliserit seviyeleri ile düşük HDL (iyi) kolesterol seviyeleri, arterlerde yağ birikintilerinin oluşmasına katkıda bulunarak onları daralttığı ve kan akışını engellediği için iskemik kalp hastalığı için en yaygın ikinci risk faktörü olarak kabul edilmektedir. Dünya Sağlık Örgütü'ne göre, yüksek kolesterol tahmini olarak 2.6 milyon kişinin ölümüne neden olmuştur (Mozaffarian vd., 2015).

Diabet: Kardiyovasküler hastalıklar diyabetli hastalarda morbidite ve mortalitenin önde gelen nedenidir (Care, 2019). Diyabeti olan yetişkin hastalarda kalp hastalığı oranı, diyabeti olmayanlara kıyasla erkeklerde 2.5 kat, kadınlarda ise 2.4 kat daha yüksektir (Mozaffarian vd., 2015).

Obezite: Obezite, KAH için bağımsız bir risk faktörüdür ve hipertansiyon, hiperlipidemi ve diabetes mellitus gibi diğer KAH risk faktörlerinin gelişme riskini de

artırır (Wilson vd., 2002). Veri grubunda obez hastalarında bulunduğu bir çalışmada veriler demografik özellikler, sigara kullanımı, fiziksel aktivite ve alkol alımına göre düzenlendikten sonra koroner kalp hastalığına yakalanma olasılığının iki kat daha fazla olduğunu göstermiştir (Ndumele vd., 2016). Obezitenin kardiyovasküler morbidite için bağımsız bir risk faktörü olduğuna işaret eden kanıtlara rağmen, bazı yazarlar aşırı kilolu ve obez hastalarda daha iyi sonuçlar tanımlamıştır (Akin ve Nienaber, 2015).

Hareketsiz yaşam tarzı: Egzersiz, KAH gelişimini önlemede koruyucu bir faktördür. Tüm kıtaları temsil eden 52 ülkede gerçekleştirilen ve 15152 vaka ile 14820 kontrolü içeren bir çalışmada, fiziksel hareketsizliğin kalp krizi riskini %12.2 artırdığını ortaya koymuştur (Yusuf vd., 2004). Birçok gözlemsel çalışma, egzersizi kendi kendine seçen bireylerin daha düşük morbidite ve mortaliteye sahip olduğunu göstermiştir.

Sağlıksız beslenme: Yüksek yağlı ve kolesterolü gıdaların tüketimi, yüksek tuz alımı, şekerli ve işlenmiş gıdaların aşırı tüketimi, yetersiz meyve ve sebze tüketimi, düşük lif alımı ve aşırı alkol tüketimi gibi sağlıksız beslenme alışkanlıkları bir yandan kolesterol seviyelerinin yükselmesine ve kan basıncının artmasına sebep olurken bir yandan da obezite, tip 2 diyabet ve metabolik sendrom riskini artırarak koroner arterlerde plak birikimine yol açmaktadır. Bu durumlar koroner arter hastalığı riskini artırmaktadır (Erdem vd., 2017; Yılmazel ve Ahcıoğlu, 2021).

Stres: Kronik stres ve aşırı öfke KAH gelişiminde bir risk faktörü olarak ifade edilebilir. Dolaylı olarak yüksek tansiyon, sigara, aşırı yeme ve fiziksel aktivite eksikliği gibi diğer risk faktörlerini de etkileyebilir (Chandola vd., 2008).

Bu geleneksel kardiyovasküler risk faktörlerine ek olarak, yeni risk faktörleri de araştırmalara konu olmaktadır. Bunlara alkolik olmayan yağlı karaciğer hastalığı, Kronik böbrek hastalığı, Sistemik lupus eritematozus (Kelebek hastalığı), Romatoid artrit (İltihaplı Romatizma), sindirim sisteminde görülen İnflamatuar bağırsak hastalığı (IBD), HIV virüsü, Tiroid hastalığı, Testosteron ve D vitamini eksikliği olarak sayılabilir (Hajar, 2017).

2.3.3. Hastalık Tanısı

KAH teşhisi genellikle anamnez, fiziksel muayene ve teşhis testlerinin kombinasyonuna dayanmaktadır. Teşhiste önemli bir ilk adım olan anamnez, çoğu hastada tanı koymak için genellikle yeterlidir. Ancak tanıyı doğrulamak, diğer

olasılıkları elemek ve hastalığın ciddiyetini değerlendirmek için fiziksel muayene ve ek incelemeler de gereklidir. Anamnez, hastanın semptomlarını, aile öyküsünü, tıbbi durumlarını ve KAH için risk faktörlerini ayrıntılı bir şekilde değerlendirmektedir. Fiziksel muayene, hastanın vital bulgularını kontrol etme, kalp seslerini dinleme ve göğüs ağrısı, nefes darlığı ve anormal kalp ritimleri gibi kalp hastalığı belirtilerini değerlendirme işlemini içermektedir (Williams ve Hare, 2011).

Tanısal değerlendirme, test öncesi olasılığın (TÖO) belirlenmesi ve SCORE sistemi kullanılarak riskin hesaplanmasıyla başlar. TÖO %15'in altındaysa başka bir değerlendirmeye gerek yoktur. Ancak, TÖO'su %15 ile %65 arasında olan hastalarda koroner arter hastalığını teşhis etmek için invaziv olmayan incelemeler önerilir. TÖO'nun %65 ile %85 arasında olduğu durumlarda fonksiyonel görüntüleme çalışması yapılması uygundur. TÖO'nun %85'i aşması koroner arter hastalığının varlığını düşündürür ve hastanın şikayetleri göz önünde bulundurularak önceden invaziv olmayan incelemeler yapılmadan koroner anjiyografi düşünülebilir (Members vd., 2013).

Taniya yardımcı olmak için çeşitli invaziv olmayan testler yapılabilir. Bunlar arasında elektrokardiyografi, transtorasik ekokardiyografi, dobutamin stres ekokardiyografi, egzersiz stres testleri, miyokardiyal perfüzyon sintigrafisi ve koroner bilgisayarlı tomografik anjiyografi (CTA) sayılabilir. Test seçimi hastanın klinik durumu, yerel uygunluk ve ilgili klinik kılavuzlar gibi çeşitli faktörlere bağlıdır.

KAH için teşhis testleri, invaziv ve invaziv olmayan görüntüleme testlerini içermektedir. Testlere aşağıdaki gibi ifade edilebilir;

Elektrokardiyogram (EKG): Kalbin ritmini ve elektriksel aktivitesini kontrol etmek için vücudun belirli konumlarına bağlanan sensörlerin kalbin her atışında üretilen sinyalleri kaydettiği bir testtir. KAH şüphesi olan her hastadan istirahat halinde 12 derivasyonlu EKG verilerinin alınması önerilmektedir. KAH hastalarının büyük çoğunluğunda (yaklaşık %70) normal EKG gözlemlenirken, geriye kalanlarda grafikte yer alan t dalgası anormallikleri gözlemlenebilmektedir (Topol ve Teirstein, 2015).

Transtorasik ekokardiyografi: Kalbin, yapısını ve fonksiyonunu değerlendirmek için kalbin görüntüsünü ultrason (ses dalgaları) kullanarak oluşturan bir testtir. Kalbin, dört odacığını, kalp kapakçıklarını ve kan damarlarını gösteren en yaygın ekokardiyograf türüdür (Zhang vd., 2020).

Dobutamin stres ekokardiyografi: Kalbin, Dobutamin adı verilen bir ilaçla çalıştırılması sırasında çekilen bir ultrason taramasıdır. Dobutamin egzersizi taklit ederek kalbin egzersiz (stres) yapmaya nasıl tepki verdiğinin görülmesini sağlamaktadır (Al-Lamee vd., 2019).

Egzersiz Stres Testi: Kalp-damar hastalıklarında yaygın bir şekilde kullanılan bir testtir. Egzersiz testi sırasında hastalar koşu bandında yürümek veya sabit bir bisiklette pedal çevirmek gibi kalp atış hızlarını etkili bir şekilde yükselten fiziksel aktivitelerde bulunurlar. Eş zamanlı olarak bir bilgisayar hastanın EKG kayıtlarını analiz ederek standart bir EKG'de belirgin olmayabilecek anormallikleri ortaya çıkabilmektedir. Süreç boyunca hastanın göğüs ağrısı, bayılma, iskemik değişiklikler veya aritmi gibi semptomlar takip edilir. Ayrıca, EKG'ye yansıyan kalp hızı ve kan basıncı tepkisinin yanı sıra oksijen saturasyon seviyeleri gözlemlenir (Sirico vd., 2019).

Koroner Bilgisayarlı Tomografik Anjiyografi: Ön kol toplar damarından bir kontrast madde verilerek koroner arterlerin görüntülediği bir yöntemdir. Test, 10-20 saniye arasında gerçekleşen nefes tutma sürecinde tarama yapılarak gerçekleştirilir. Analiz sonucunda koroner arterlerde arteriyel sertleşmeye yol açabilecek plak birikiminin varlığını belirlemeyi amaçlamaktadır. Ayrıca, plak birikimlerinin neden olduğu herhangi bir darlık veya tıkanıklığın şiddeti belirlenerek tedavinin gerekliliği ve yaklaşımına ilişkin karar verme sürecine yardımcı olunur (Abdelrahman vd., 2020).

2.4. İridoloji

2.4.1. Tanım ve Genel Bakış

İridoloji, gözün irisindeki desenleri ve renk değişimlerini analiz ederek bireyin sağlık durumunu ve genetik özelliklerini değerlendiren, hastalıkları önlemeyi veya erken teşhis etmeyi amaçlayan, tamamlayıcı ve alternatif tıp dalı olarak da bilinen bir bilim dalıdır (Noworol, 2020). Gözün renkli kısmı olan irisin, vücuttaki belirli organlara ve sistemlere karşılık gelen refleksif bölgeler içerdiğine inanılmaktadır. İridologlar, iris işaretlerini ve değişikliklerini inceleyerek potansiyel dengesizlikleri tespit etmeyi, belirli sağlık koşullarına yatkınlıkları belirlemeyi ve sağlığı iyileştirmek için kişiselleştirilmiş öneriler sunmayı amaçlamaktadır. İridoloji, irisin vücudun bir aynası olarak düşünüldüğü, sağlık durumunu yansıttığı ve sinir, sindirim, dolaşım ve bağışıklık sistemleri de dahil olmak üzere çeşitli vücut sistemleri hakkında değerli

bilgiler sağladığı ilkesine dayanmaktadır. İridologlar, iris işaretlerinin ve desenlerinin dikkatli bir şekilde gözlemlenmesi ve analiz edilmesi yoluyla, potansiyel zayıflıkları, iltihaplanma alanlarını ve sağlık sorunlarının altında yatan potansiyel nedenleri ortaya çıkarmayı amaçlamaktadır (Dopke ve Battello, 2017; Muzamil vd., 2020).

İridoloji geleneksel tıpta birincil teşhis aracı olarak kabul edilmese de, bütüncüleştirici ve bütünsel sağlık hizmetlerinde tamamlayıcı bir yaklaşım olarak sıklıkla kullanılmaktadır. İridolojinin belirli hastalıkları teşhis etmediğini, bunun yerine bireyin genel sağlığının bütünsel bir değerlendirmesini sağladığını ve daha fazla dikkat veya destek gerektirebilecek alanları vurguladığını belirtmek önemlidir (Sumathy, 2020; Vresdian vd., 2022).

Uygulamalar çeşitli araştırmacılar tarafından geliştirilen farklı yaklaşımlar ve yorumlarla zaman içinde gelişmiştir. Bilimsel geçerliliği konusunda süregelen tartışmalara ve standartlaştırılmış protokollerin eksikliğine rağmen, sağlık değerlendirmeleri ve sağlıklı yaşam stratejileri konusunda alternatif bakış açıları arayan birçok kişinin ilgisini çekmeye devam etmektedir (Esteves vd., 2021).


2.4.2. Tarihçe

İridoloji uygulamasının kökleri, göz incelemelerinin bir teşhis aracı olarak kullanıldığı eski uygarlıklara kadar uzanmaktadır. Eski Mısırlılar, Çinliler ve Hindistanlıların genel sağlığı anlamada gözlerin potansiyel önemini fark ettiklerine inanılmaktadır. Bununla birlikte, iridolojinin ayrı bir uygulama olarak resmi gelişimi 19. yüzyılda başlamıştır (Noworol, 2020).

İridolojinin erken gelişimindeki kilit isimlerden biri Macar bir doktor olan Ignatz von Peczely'dir. Peczely 1861'de tesadüfen bir baykuşun yaralanması ile irisindeki değişiklikler arasında bir ilişki gözlemleyerek bu gözlemin iridoloji kavramını formüle etmesine yol açmıştır. Buradan hareketle iristeki belirli işaretlerin ve desenlerin bir kişinin sağlık koşulları ve yatkınlıkları hakkında bilgi sağlayabileceğini öne sürmüştür (Jensen, 2012). Peczely'nin çalışmalarını temel alan başka önemli isimler de iridolojinin ilerlemesine katkıda bulunmuştur. 20. yüzyılın başlarında İsveçli rahip Nils Liljequist kapsamlı bir araştırma yürüterek iridoloji üzerine ilk kapsamlı ders kitabını yayınlamıştır. Çalışmada, iris işaretlerini sınıflandırarak belirli iris bölgeleri ile ilgili vücut organları arasında bağlantılar önermiştir (Jensen, 2012; Norn, 2003).

Sonraki yıllarda, Avrupa ve Amerika Birleşik Devletleri de dahil olmak üzere farklı ülkelerden çeşitli iridologlar iridoloji bilgisini ve uygulamalarını daha da


geniřletmiřtir. Bernard Jensen, Dorothy Hall ve Josef Deck gibi nemli iridologlar iris haritalama tekniklerini geliřtirerek konunun poplaritesini artırmıřlardır (Berdonces, 2015; Sharan, 1989). Bernard Jensen, diğeri iki arařtırmacı ile birlikte iridolojinin geliřimine nemli katkılarda bulunmuřtur. Ancak, iridoloji alanını zellikle ileriye gtren durum Jensen'in arařtırmaları ve iris haritasını oluřturmasıdır. İris temel olarak řekil 2.10'da yer aldıđı gibi 7 ana blm olarak ifade edilebilir. Bu blmler gzbebeđinden dıřarı dođru bařlayarak iris dıř halkasına kadar ayrılmıřtır. İlk iki alanın temsil ettiđi ve řekil olarak da dzensiz olan alan, sindirim sisteminde yer alan mide ve bađırsak gibi organları vcudun geri kalanından ayırmaktadır. Bu blgenin iinde mide, ince ve kalın bađırsaklar bulunmakta ve otonom sinir sistemini temsil etmektedir (Jensen, 2012). İrisin 7 blme blnmesi ile meydana gelen alanlar sırayla; 1. mide blgesi, 2. bađırsak blgesi, 3. pankreas, kalp, bronřlar, 4. omurga, vajina, uterus, prostat, 5. beyin, akciđer, karaciđer, dalak, bbrek, tiroid, 6. kaslar, motor sinirler, 7. deri, lenfatik ve dolařım sistemleri bulunmaktadır.



řekil 2.9. İris blmlenmesi (Pau, 2019)

Jensen'in 50 yıldan uzun sre klinik deneyler yaparak geliřtirmiř olduđu sađ ve sol irise ait iridoloji haritası řekil 2.10'daki gibidir. Haritada vcudun sađ tarafındaki organlar sađ iriste temsil edilirken, sol taraftaki organlar sol iriste konumlanmaktadır. Vcudun orta blmnde yer alan organlar ise her iki iriste de yer almaktadır. Haritadaki organlara ait konumlar yaklaşık olarak 150 yıllık deneysel alıřmalar sonucunda meydana gelmiřtir. řekil 2.10'daki irislerde vcudun farklı blmlerine karřılık gelen alanları gstermektedir. Yaklaşık olarak sađ gzde 80 ve sol gzde 86 blgeden oluřan iris haritasında her organ ya da sistem blgeler ile temsil edilmektedir.

Haritada organ ya da dokuları temsil eden bölgeler saat sistemi esas alınarak ifade edilmektedir. Kalp bölgesi sol iriste 2 ile 4 arasında yer alırken, akciğer sol iriste 2-3 saatleri arasında ve sağ iriste ise 9-10 saatleri arasında konumlanmıştır (Jensen, 2012; Simon vd., 1979).




Şekil 2.10. İris haritası (Health, 2023)

İridoloji, tarihi boyunca geleneksel tıp çevresinden gelen şüphencilik ve eleştirilerle karşılaşmıştır. Eleştirmenler, iridolojinin geçerliliğini ve güvenilirliğini destekleyen bilimsel kanıtların eksikliğinin ana akım tıp içinde kabul görmesini engellediğini savunmaktadır. Bununla birlikte; iridolojinin savunucuları, genel sağlık konusunda değerli bilgiler sunduğunu ve bütünsel ve bütünleştirici sağlık hizmetleri ortamlarında diğer teşhis yöntemlerini tamamlayabileceğini savunmaktadır.

2.4.3. İris İşaretleri

Gözün irisi, vücudumuzdaki çeşitli işlevleri kontrol etmekten sorumlu olan sempatik ve parasempatik sinir sistemleriyle doğrudan bir bağlantıya sahiptir. Bu bağlantı, vücudun farklı bölgelerinden gelen bilgilerin irise iletilmesini sağlar. İris dokusu sinirlerden ve kandan sinyaller olarak vücudun diğer bölgelerinden elektriksel ve biyokimyasal olarak bilgiler taşır. Bu bilgiler, iris yüzeyinde iridolojide gözlemlenebilen belirli işaretler yaratabilmektedir (Pau, 2019).

İridolojiye göre iris, farklı organlara, dokulara ve vücut sistemlerine karşılık gelen belirli refleksif bölgelere ayrılmıştır. Bu iris bölgelerindeki değişikliklerin veya işaretlerin, ilgili vücut bölümlerinin sağlığı ve işleyişi hakkında bilgi sağlayabileceğine inanılmaktadır. İridologlar bu bölgeleri inceleyerek potansiyel dengesizlikleri veya endişe alanlarını tespit etmeyi amaçlamaktadır. İridoloji, belirli iris özelliklerinin bir bireye özgü olduğunu ve belirli sağlık koşullarına yatkınlıkları veya kırılganlıkları gösterebileceğini öne süren yapısal desenlerin olduğunu kabul eder. Bu desenler iris rengi, dokusu, yapısı ve işaretlerindeki varyasyonları içerebilir. İridologlar, bu yapısal kalıpları değerlendirerek bireyin genel sağlık eğilimleri ve potansiyel riskleri hakkında bilgi edinmeyi amaçlar. Çalışmalarda bireyin sağlığı hakkında bilgi edinmek için çeşitli iris işaretleri gözlemlenir ve analiz edilir. Bu işaretler arasında Şekil 2.11’de de görüldüğü gibi iris rengindeki farklılıklar, lekeler, gerilmeler, çizgiler veya lezyonların yanı sıra kriptler, oluklar veya halkalar gibi kavramlar da yer alabilmektedir. Bu işaretlerin her biri, ilgili refleksif bölge ve genel iris haritası bağlamında yorumlanır (Jensen, 2012; Lodin ve Demea, 2009; Pau, 2019).



Şekil 2.11. İris deseninde a) bükülme, b) halka oluşması, c) gerilme, d) siyah nokta, e) beyaz nokta, f) hem siyah hem beyaz nokta belirtilerine örnekler (Lodin ve Demea, 2009)

İridolojinin genellikle tek başına bir teşhis yönteminden ziyade tamamlayıcı bir teşhis aracı olarak kullanıldığını belirtmek önemlidir. Bireyin sağlık durumunun daha kapsamlı bir şekilde anlaşılmasını sağlamak için en iyi şekilde diğer geleneksel ve bütünsel değerlendirmelerle birlikte kullanılır.

3. LİTERATÜR ÖZETİ

Bu bölüm iki kısma ayrılmıştır. İlk olarak iridoloji ile ilgili genel çalışmalara yer verilmiştir. İkinci kısımda ise iridoloji ve kalp hastalıklarının birlikte çalışıldığı yayınlara ait bilgiler yer almaktadır.

3.1. İridoloji ile İlgili Çalışmalar

Literatürde iridoloji ile gerçekleştirilmiş birçok çalışma yapılmıştır. Bu çalışmalardan bazıları aşağıda açıklandığı gibidir;

(Ma vd., 2012)'de yapılan çalışmada gastrointestinal hastalıklardan kaynaklı olarak iriste oluşan geometrik yapı değişikliklerinin gözbebeği ve kolarete dayalı özelliklerinin incelenmesi amaçlanmıştır. Önerilen özelliklerin etkililiğini ve klinik teşhiste uygulanabilirliğin önemini kanıtlamakta ve otomatik hastalık teşhisi için güvenilir bir tanı performansına sahip olduğunu bildirmişlerdir.

(Bansal vd., 2015)'de yapılan çalışmada iridolojiden faydalanan iris tanıma sistemi yöntemlerini kullanarak diyabet belirleme amaçlanmıştır. 40 diyabet hastası ve 40 sağlıklı bireyin bulunduğu grupla yapılan çalışmada dalgacık dönüşümü temelli iris öznitelikleri kullanılmıştır. SVM ile gerçekleştirilen sınıflandırma işleminde genel doğruluk değeri %87.5 olarak bulunmuştur.

(Samant ve Agarwal, 2019)'de yapılan çalışmada iridoloji kullanarak tip-2 diyabet için bir teşhis modeli önerilmiştir. Çalışmada 180 diyabetli ve 158 diyabetli olmayan olmak üzere 338 gönüllü yer almıştır. İris haritasına göre pankreas organına ait bölge için dalgacık dönüşümü temelli istatistiksel ve dokusal parametreler elde edilmiştir. Çalışmanın sonucunda, RF sınıflandırıcısı ile %89.63'lük en iyi sınıflandırma doğruluğu elde edilmiştir. Maksimum özgüllük ve duyarlılık sırasıyla 0.9687 ve 0.988 olarak belirlenmiştir. Aynı yazarlar bu çalışmaya ek olarak hastalara ait fizyolojik özelliklerin de dahil edildiği başka bir çalışma daha yapmışlardır. İris ve fizyolojik özelliklerin hibrit olarak kullanılması ile sınıflandırma doğruluğu %95'in üzerine çıkmıştır.

(Önal vd., 2023)'de yapılan çalışmada görüntü işleme, iridoloji ve derin öğrenme yöntemlerinin birleştirilmesi ile iris görüntülerini kullanarak diyabet teşhisi amaçlanmıştır. İris haritasındaki pankreas bölgesi Evrişimsel Sinir Ağları girdi parametresi olarak belirlenmiştir. VGG-16 mimarisi kullanılarak %80 sınıflandırma doğruluğu elde edilmiştir.

(Sruthi vd., 2022)'de yapılan çalışmada tip-2 diyabetin invaziv olmayan teşhisi için derin öğrenme tabanlı bir yöntem önerilmiştir. Çalışmada yer alan 178 gönüllünün 95'i diyabet hastası ve 83'ü sağlıklı kategoride yer almaktadır. İris haritasındaki pankreas bölgesinin girdi olduğu Evrişimsel Sinir Ağları'nda bir çok mimari denenmiş ve Alexnet mimarisi ile %95.85 ile en yüksek sınıflandırma başarısı elde edilmiştir.

(Hussein vd., 2013)'de yapılan çalışmada böbrek anormalliklerini tespit etmek için iridoloji tabanlı bir yöntem önerilmiştir. Çalışmada 168 kronik böbrek yetmezliği olan hasta ve 172 sağlıklı grubu olmak üzere toplamda 340 gönüllü yer almaktadır. İriste yer alan böbrek konumundan dalgacık dönüşümü ve gabor filtresi kullanılarak enerji ve entropi değerleri öznitelik olarak kullanılmış ve Uyarlamalı Sinirsel Bulanık Çıkarım (Adaptive Neuro-Fuzzy Inference System, ANFIS) yöntemi ile sınıflandırma gerçekleştirilmiştir. Sonuç olarak böbrek sorunu olan hastaların tahmini %82 ve hasta olmayan gönüllülerin %93 doğruluğunda sınıflandırıldığı bildirilmiştir.

(Muzamil vd., 2020)'de yapılan çalışmada kronik böbrek hastalığının erken aşamada teşhis edilebilmesi için iris tabanlı bir yöntem önerilmiştir. İris görüntülerinden öznitelikleri çıkarmak ve sınıflandırma yapmak amacıyla Evrişimsel Sinir Ağları kullanılmıştır. Önerilen yöntem ile test görüntülerindeki sınıflandırma doğruluğu %96.8 olarak bulunmuştur.

(Rehman vd., 2021)'de yapılan çalışmada makine öğrenimi algoritmaları dahil edilerek iris özelliklerine dayalı bir invaziv olmayan bir teknik ile kronik karaciğer hastalıklarını tahmin eden bir yöntem önerilmiştir. 453'ü kronik karaciğer hastalığına sahip ve 426'sı sağlıklı olmak üzere toplamda 879 gönüllünün yer aldığı çalışmada gönüllülerin irislerindeki karaciğer konumlarından 33 özellik çıkarılmış ve bunlara ek olarak gönüllülere ait 22 fizyolojik parametre de analiz edilmiştir. On bir farklı sınıflandırıcının birleştirilmesi sonucunda önerilen invaziv olmayan modelin kronik karaciğer hastalıklarını %98 doğrulukla tahmin etme kapasitesine sahip olduğu ifade edilmiştir.

(Gül, 2017)'de yapılan tez çalışmasında, yüksek kolesterolün bir belirtisi olan sodyum halkasının kalınlık değerini hesaplayarak kolesterol değerini bulmaya çalışan bir yöntem önerilmiştir. İlk aşamada İntegral Diferansiyel Operatörü ile gözbebeğinin konumlarını elde edilmiş, ardından gözbebeği sınırlarından sağ ve sol tarafa çizilen çizgiler boyunca renk değerlerinin değişimi incelenmiş ve halkanın genişliği hesaplanmıştır. Lineer regresyon yöntemin kullanıldığı modelde %77,2'ye varan doğruluk elde edilmiştir.

(Kurnaz ve Gül, 2018)'de yapılan çalışmada, sodyum halka genişliğinin hesaplanması ve hesaplanan genişlik ile kolesterol seviyesi arasındaki ilişkinin belirlenmesi amaçlanmıştır. Yüksek kolesterole sahip 15 hastadan alınan iris görüntülerinin yer aldığı çalışmada toplam kolesterol, LDL, HDL ve trigliserit değerleri ile halkanın genişlik değeri %86 doğrulukla tahmin edilmiştir.

(Özbilgin, 2019)'de yapılan çalışmada iris analizi yöntemiyle sistemik hastalıkların iristeki belirtileri incelenmiştir. İki aşamadan oluşan tezde ilk olarak göğüs, bronşlar, böbrek, karaciğer ve dalak olmak üzere beş farklı bölgenin iristeki konumlarında düzensiz yapıların tespiti yapılmıştır. İkinci aşamada ise kolesterol değeri 200 mg/dL ve üzeride olan 100 hastaya ait iris görsellerinden kolesterol değeri tahmini gerçekleştirilmiştir. Sodyum halkasının ortalama parlaklık değeri ile kolesterol değerini tahmin edilmesi lineer regresyon ile %88.82 doğrulukla bulunurken, yapay sinir ağları kullanılarak %92.98 doğruluk elde edilmiştir.

(Daniel vd., 2020)'de yapılan çalışmada kolesterol seviyesini saptamak için bir sistem önerilmiştir. Kolesterol seviyelerini; kolesterol yok (<200 mg/dL), kolesterol riski (200-239 mg/dL) ve yüksek kolesterol (>240 mg/dL) olarak tanımlanmıştır. Çalışmada iris özneteliklerini GLCM ile çıkarmış ve SVM ile sınıflandırma yapılmıştır. 75 test verisi için elde edilen doğruluk oranı %94.67 olarak ifade edilmiştir.

(Özbilgin ve Kurnaz, 2022)'de yapılan çalışmada, kişilerin kolesterol seviyeleri ve sodyum halkasının genişliği arasındaki ilişkiyi incelenmiştir. Kolesterol seviyesi 200 mg/dL ve üzeri 100 gönüllünün yer aldığı çalışmada 55 gönüllüde sodyum halkası tespit edilmiştir. Bu kişilerin irislerindeki sodyum halkasına ait ortalama parlaklık değeri ile toplam kolesterol, HDL, LDL ve trigliserit değerleri arasındaki ilişki incelenmiştir. HDL, LDL ve trigliserit seviyeleri sırasıyla %80.5, %85.1 ve %79.9 doğruluk oranlarıyla hesaplanmıştır. Ayrıca, ortalama parlaklık değeri, toplam kolesterol, HDL, LDL ve trigliserit değerleri kullanılarak çoklu doğrusal regresyon yöntemiyle %90 doğruluk oranıyla belirlenirken, yapay sinir ağları kullanıldığında bu oran %6.62 daha yüksek bulunmuştur.

3.2. Kalp Hastalıkları Kapsamında İridolojinin Kullanıldığı Çalışmalar

(Kusumaningtyas vd., 2017)'de yapılan çalışmada göz fotoğrafı çeken, ön işlemler yapan, kalp bölgesini belirleyip siyah ve beyaz piksel oranlarına bakarak özellik çıkaran ve eşikleme algoritmasını kullanarak sınıflandırma işlemi

gerçekleştiren bir mobil sistem geliştirilmiştir. Sistem %82.3 doğruluk ile sınıflandırma yapmaktadır.

(Yohannes vd., 2020)'de yapılan çalışmada klinikten alınan 110 göz fotoğrafını kullanarak kalp hastalığı potansiyeli araştırılmıştır. Çalışmada göz fotoğraflarının 55 tanesi kalp hastası kişiye aitken diğer 55 kişinin kalp probleminin olmadığı belirtilmiştir. Göz resimleri ön-işlemden geçirildikten sonra kalp bölgesi çıkarılmış, bu bölgede Canny kenar bulma ve PCA ile özellik çıkarımı gerçekleştirilmiştir. Sınıflandırma yöntemi olarak Yapay Sinir Ağları Geri Yayılım Algoritması kullanılmıştır. 22 test verisi için sistemin başarısı %95.45'e varan doğruluklara ulaşmaktadır.

(Permatasari vd., 2016)'de yapılan çalışmada iristen kalp bölgesini tespit ettikten sonra PCA ile özellik çıkarımı gerçekleştirmiş ve SVM ile sınıflandırma işlemi yaparak kalp hastalığının varlığını tespit edilmesi amaçlanmıştır. 50 kalp hastasına ve 40 kalp hastası olmayan kişilere ait göz fotoğrafı olmak üzere toplamda 90 göz verisi kullanılan çalışmada %80 sınıflandırma başarısı elde edilmiştir.

(Putra vd., 2018)'de yapılan çalışmada iristen kalp bölgesini belirledikten sonra iki farklı özellik çıkarım yöntemi kullanarak ANN ile kalp hastalığı olup olmadığının tespit edilmesi amaçlanmıştır. Özellik çıkarma yöntemi olarak GLCM ve PCA yöntemleri kullanılmıştır. 90 göz fotoğrafı kullanılan çalışmada GLCM özellik çıkarımı sonucunda 77.5% doğruluk ve PCA özellik çıkarımı sonucu 90% doğruluk ile sınıflandırma gerçekleştirilmiştir.

(Kusumaningtyas vd., 2021)'de yapılan çalışmada kalp hastalığı ve diyabet hastalığını tespit etmeyi amaçlanmıştır. Çalışmada iridoloji kamerası kullanılarak gönüllülerin sol göz görüntüleri elde edilmiştir. Analiz bölgesi çıkarıldıktan sonra bölgedeki siyah ve beyaz piksellerin oranı öznitelik çıkarımı olarak kullanılmıştır. Eşikleme yöntemi ile de sınıflandırma gerçekleştirilmiştir.

(Martiana vd., 2016)'de yapılan çalışmada iris aracılığıyla kalp hastalıklarını tespit etmek için farklı teknikleri karşılaştırmış, görüntüyü seçen ve seçilen görüntü üzerinde kenar algılama ve segmentasyon gerçekleştiren android uygulaması geliştirilmiştir.

(Gunawan vd., 2022)'de yapılan çalışmada KAH tanımlanması için iridoloji tabanlı bir çalışma gerçekleştirilmiştir. İristeki kalp bölgesinden GLCM matrisini kullanarak beş adet öznitelik çıkarılmıştır. Çeşitli SVM parametrelerini kullanarak


sınıflandırma yapılan çalışmada, Gaussian kerneli ile %91, polinom kerneli ile %89 ve doğrusal kernel ile %87 sınıflandırma doğruluğu elde edilmiştir.

(Özbilgin vd. 2023)'de yapılan çalışmada KAH tahmin edilmesi için iris analizi tabanlı bir sistem önerilmiştir. Önerilen yöntemde 94 hasta ve 104 de kontrol grubu olmak üzere 198 gönüllüye ait iris görüntüleri kullanılmıştır. Sol iristeki kalp bölgesine adaptif histogram düzenlemesi sonrasında dalgacık dönüşümü uygulanmıştır. Bölgeye ait istatistiksel ve dokusal (GLCM ve GLRLM) öznitelikler çıkarılarak öznitelik seçme işlemi sonrasında çeşitli makine öğrenmesi algoritmaları ile sınıflandırma işlemi gerçekleştirilmiştir. En yüksek sınıflandırma doğruluğu %93 ile SVM sınıflandırıcısında elde edilmiştir.



4. MATERYAL VE YÖNTEM

İris analizi ile hastalık tahmini çalışmalarında genel olarak standart bir süreç işlemektedir. Bu tez çalışmasında da iris görüntülerinden KAH tahmin etme sürecine ilişkin genel akış şeması Şekil 4.1'deki gibidir.



Şekil 4.1. Çalışmadaki sürece ait genel akış şeması

4.1. Veri Toplama

Çalışmada KAH'ın iristen tahmin edilmesi için hasta ve kontrol grubu olmak üzere iki gruptan gönüllülere ait göz görsellerine ihtiyaç duyulmaktadır. Gönüllülerden göz görüntülerini toplama işlemi için Samsun Üniversitesi Klinik Araştırmalar Etik Kurulu'nun 23 Kasım 2022 tarih ve SUKAEK-2022 12/21 sayılı kararı uyarınca etik kurul onayı alınmıştır. Bu kapsamda hasta ve kontrol grubu için dahil olma ve dışlama şartları belirlenmiştir.

KAH grubu için dahil olma şartları; 18 yaşından büyük, 2019 yılı Avrupa Kardiyoloji Cemiyeti (ESC) Kronik Koroner Sendromlar (KKS) tanı ve tedavi kılavuzu uyarınca KKS klinik senaryolarından en az birinin varlığı: (i) KAH'dan şüphelenilen ve “stabil” anjinal semptomları ve/veya dispnesi olan hastalar; (ii) yeni başlayan kalp yetmezliği (KY) veya sol ventrikül (LV) disfonksiyonu olan ve KAH şüphesi olan hastalar; (iii) Akut Koroner Sendrom (AKS)'den <1 yıl sonra stabil semptomları olan asemptomatik ve semptomatik hastalar veya yakın zamanda revaskülarizasyon yapılmış hastalar; (iv) KKS tanısı veya revaskülarizasyonundan > 1 yıl sonra asemptomatik ve semptomatik hastalar; (v) anjina ve şüpheli vazospastik veya mikrovasküler hastalığı olan hastalar; ve (vi) rutin taramalarda KAH saptanan asemptomatik hasta olmasıdır.

Kontrol grubu için dahil olma şartları ise 18 yaşından büyük, asemptomatik, yaş-cinsiyet-demografik özellikler açısından çalışma grubu ile benzer, iskemik kalp hastalığı öyküsü, semptom ve bulgularının olmadığı katılımcılardır.

Her iki grup için de oküler kronik hastalıkları olan, oküler cerrahi öyküsü olan ve heterokromiye sahip hastalar çalışmadan dışlanmıştır.

Göz görüntüleri Giresun Üniversitesi Eğitim ve Araştırma Hastanesi Kardiyoloji polikliniğinde toplanmıştır. Gönüllülerin hasta ya da kontrol olarak etiketlenmesi poliklinikteki uzman kardiyoloji doktorları tarafından sağlanmıştır.

4.1.1. Göz Görüntülerinin Elde Edilmesi

Şekil 4.2’de gönüllülerden göz görüntülerinin alındığı sistem ve örnek bir görüntü alma görseli yer almaktadır. Görüntüler alınırken sağ-sol ve ileri-geri hareketin sağlandığı göz muayene sistemi kullanılmıştır. Sistem üzerine görüntülerin çekildiği fotoğraf makinesi yerleştirilmiştir.



(a)



(b)

Şekil 4.2. Çalışmadaki (a) Görüntü alma sistemi (b) Örnek bir göz görüntüsü alınma aşaması

Görüntüler 24 megapiksel çözünürlüğünde Nikon D3300 DSLR fotoğraf makinesi ile alınmıştır. Göz görüntüsü çekimi gibi yakın nesnelerin görüntülerini çekmek için yakın mesafede odaklamayı sağlayan lenslerin kullanılması gerekmektedir. Bu bağlamda çalışmada lens olarak Nikon AF-S DX Mikro Nikkor 85 MM kullanılmıştır. Aynı zamanda fotoğraf makinesine entegre olarak led aydınlatma sağlayan ring flaş aparatından faydalanılmıştır. Bu sayede göz görüntüleri standart bir

ışık kaynağı ile alınmıştır. Tablo 4.1 ve Tablo 4.2’de fotoğraf makinesi ve lens ile alakalı teknik özellikler verilmektedir.

Tablo 4.1. Verilerin alındığı fotoğraf makinesi teknik özellikleri.

Çözünürlük	24 Mp
Ekran Boyutu	3 inç
Fotoğraf Çözünürlüğü	6000x4000
Hafıza Kartı Tipi	SD
Hafıza Kartı	SDHC
Kamera Formatı	DX / (1.5x Crop Factor)
Sensör Boyutu	CMOS, 23,2 x 15,4 mm
Video Çözünürlüğü	1920 x 1080
Marka	Nikon


Tablo 4.2. Fotoğraf makinesindeki lense ait teknik özellikler

Odak Uzaklığı	85 mm
Filtre Çapı	52 mm
Ağırlık	355 g
Minimum Diyafram Açıklığı	F/32
En Yakın Odaklama Mesafesi	0.286m
Boyut	73x73x99mm
Maximum Diyafram Açıklığı	F/3,5
Marka	Nikon

Şekil 4.3 ve Şekil 4.4'te göz görüntülerine ait örnekler yer almaktadır. Şekil 4.3'te KAH grubuna ait gönüllülerin göz görselleri yer alırken Şekil 4.4'te Kontrol grubuna ait görseller verilmiştir.



Şekil 4.3. KAH grubundaki gönüllülere ait göz görüntüleri



Şekil 4.4. Kontrol grubundaki gönüllülere ait göz görüntüleri

4.1.2. Biyodemografik Sağlık Profili Verileri


Göz görüntülerine ek olarak gönüllülere yöneltilen sorular vasıtasıyla fizyolojik, yaşam tarzı ve sağlık durumları ile ilgili bilgiler de elde edilmiştir. Toplamda 14 tane olan bu parametrelere ait bilgiler Tablo 4.3'te yer almaktadır. Bu bilgilerle çalışmada yer alan kişiler istatistiksel olarak incelenecek ve sınıflandırma aşamasında bu öz nitelikler iris öz niteliklerine eklenerek performansa etkisi araştırılacaktır.

Tablo 4.3. Biyodemografik sađlık profili 6znitelikleri ve veri tipleri

6znitelik İsmi	Veri tipi	Açıklama
Cinsiyet	Kategorik	G6n6ll6l6lerin cinsiyetini belirten parametredir. (Erkek=1 ve Kadın=0)
Yaş	N6merik	G6n6ll6l6lere ait yaş bilgisidir.
Boy	N6merik	G6n6ll6l6lere ait cm cinsinden boy bilgisidir.
Kilo	N6merik	G6n6ll6l6lere ait kg cinsinden kilo bilgisidir.
VKİ	N6merik	Boy ve kilo bilgisi kullanılarak hesaplanan V6cut Kitle İndeksi'dir.
VKİ	Kategorik	VKİ deęeri 30'dan b6y6k eřit ise 1, k6ç6kse 0 deęerini alan obezite parametresidir.
Aile 6yk6s6	Kategorik	Ailede Koroner Arter Hastası olması durumunda 1, olmaması durumunda 0 deęerini almaktadır.
Sigara Kullanma	Kategorik	Sigara kullanılması durumunda 1, kullanılmaması durumunda 0 deęerini almaktadır.
Alkol Kullanma	Kategorik	Alkol kullanılması durumunda 1, kullanılmaması durumunda 0 deęerini almaktadır.
Egzersiz	Kategorik	Egzersiz yapıyorsa ya da g6n ierisinde hareketli ise 1, deęil ise 0 deęerini almaktadır.
Kolesterol	Kategorik	Kolesterol deęeri y6ksek ise ya da kolesterol ilacı kullanıyorsa 1, dięer durumlarda 0 deęerini almaktadır.
Diyabet	Kategorik	řeker hastalıęına sahipse 1, deęilse 0 deęerini almaktadır.
Stres	Kategorik	Stres durumunu g6steren parametredir. Stresli hissediyorsa 1, hissetmiyorsa 0 deęeri almaktadır.
Tansiyon	Kategorik	Tansiyon deęeri normal deęil ise ya da tansiyon ilacı kullanıyorsa 1, dięer durumlarda 0 deęerini almaktadır.

4.2. Görüntü Ön-İşleme

Göz görüntülerini elde ettikten sonra, analize hazırlamak için birkaç ön işleme adımından geçmeleri gerekmektedir. Ön-işleme süreci iris iç ve dış sınırlarının bulunması, iris normalizasyonu, analiz bölgesinin bölütlenmesi ve görüntü iyileştirme aşamalarından oluşmaktadır. Şekil 4.5'te aşamalara ait örnek bir süreç yer almaktadır. Şekilde yer alan numaralar süreçleri belirtmektedir. 1. Aşamada göz görüntüsünün renkli formattan gri formata dönüşümü, 2. Aşamada göz görüntüsü içerisinde irisin iç ve dış sınırlarının bulunması ve çizdirilmesi, 3. Aşamada irisin dairesel formattan dikdörtgen formata dönüştürülmesi, 4. Aşamada iristeki kalp konumlarına ait bölgenin tespiti ve bölütlenmesi ve son aşamada analiz bölgesine ait görüntünün iyileştirilmesi yer almaktadır.



Şekil 4.5. Göz görüntüsü ön-işleme süreci aşamaları

4.2.1. Gözbebeği ve İris Konumunun Belirlenmesi

Bu aşamada, görüntü içerisinde gözbebeği ve iris konumlarının tespiti gerçekleştirilmektedir. Gri formata dönüştürülen görüntü içerisindeki iris konumları integral diferansiyel operatörü (IDO) (Daugman, 2009) yardımıyla gerçekleştirilir. İDO yöntemi, göz bebeği ve göz akı renklerinin değerlerini kullanarak yüksek doğrulukta irisin iç ve dış sınırlarını belirleyebilmektedir. Yöntemde amaç, gri formattaki görüntünün analiz sonucunda irisin nokta koordinatları ile iç ve dış


sınırlarının bulunmasıdır. Merkez noktayı bulabilmek için tüm potansiyel merkez noktaları değerlendirilir. Değerlendirme sırasında, her olası merkez noktasından daireler çizilerek daire üzerindeki piksellere ait renk tonu değerleri incelenir ve bu noktaların integral değerleri hesaplanır. Renk değerleri siyahın “0” ve beyazın “255” olarak gösterildiği ve bu değerler arasında değişen rasyonel sayılardan oluşmaktadır. Bir daire için renk tonu değerlerinin değerlendirilmesi tamamlandıktan sonra, işlem yeni bir daire için tekrarlanır ve potansiyel merkez noktasından olan mesafe giderek artırılır. Bu işlem belirlenen tüm mesafe değerleri incelenene kadar devam eder. Potansiyel bir merkez noktasından tüm mesafeler için integral hesaplaması bittikten sonra, ardışık dairelerin integral sonuçları arasındaki farklar belirlenir. Bu fark değerleri daha sonra bir Gauss fonksiyonu kullanılarak yumuşatılır. Bu farklar arasındaki en yüksek mutlak değer, en belirgin renk tonu geçişine sahip bölgeyi tanımlar. Sonuç olarak, bu değerle ilişkili koordinatlar irisin merkez koordinatlarını gösterirken, uzunluk irisin iç veya dış dairesinin yarıçapını temsil eder. Yöntemin matematiksel ifadesi aşağıdaki denklemdeki gibidir.

$$\max_{r,x_0,y_0} \left| G_{\sigma}(r) \frac{\partial}{\partial r} \oint_{r,x_0,y_0} \frac{I(x,y)}{2\pi r} ds \right| \quad (4.1)$$

Burada; $I(x, y)$ ifadesi, I görüntüsündeki (x, y) konumunun renk tonu değerini göstermektedir. x_0 ve y_0 olası merkez noktasının koordinatlarını, r sembolü ise olası merkez noktasına uzaklığı temsil etmektedir. G_{σ} ise σ standart sapmalı Gauss fonksiyonunu göstermektedir.

4.2.2. Normalizasyon İşlemi

İrisin iç ve dış konumlarının tespit edilmesinden sonraki aşama normalizasyon işlemidir. Normalizasyon işleminde iris dikdörtgen formata dönüştürülerek analiz edilmesi daha kolay ve standart bir hale getirilmektedir. Şekil 4.6’da görsel olarak ifade edilen Daugman Rubber Sheet yöntemi (Daugman, 2009) sıklıkla kullanılan normalizasyon yöntemlerinden bir tanesidir ve bu çalışmada da söz edilen yöntem kullanılmıştır.



Şekil 4.6. İris normalizasyonu

İris görüntüsünün $I(x, y)$ kartezyen koordinatlardan kutupsal gösterime yeniden eşlenmesi aşağıdaki eşitlikteki gibi ifade edilebilir.

$$I(x(r, \theta), y(r, \theta)) \rightarrow I(r, \theta) \quad (4.2)$$


$$x(r, \theta) = (1 - r)x_p(\theta) + rx_l(\theta) \quad (4.3)$$

$$y(r, \theta) = (1 - r)y_p(\theta) + ry_l(\theta) \quad (4.4)$$

Burada $I(x, y)$ iris bölgesi, (x, y) kartezyen koordinatları, (r, θ) normalize edilmiş kutupsal koordinatlar ve x_p, y_p ve x_l, y_l ifadeleri θ yönündeki gözbebeği ve iris sınır koordinatlarını ifade etmektedir.

4.2.3. ROI'nin Tespiti

Normalizasyon işlemi tamamlandıktan sonra analizlerin yapılacağı bölgenin (Region of Interest, ROI) belirlenmesi gerekmektedir. Öznitelik çıkarma işlemi bu bölgeye uygulanarak gerçekleştirilmektedir. İriste Şekil 2.4'te belirtildiği gibi her organın ya da dokunun özel konumu yer almaktadır. Bu çalışmada kapsamında KAH ele alındığından ötürü iriste yer alan kalp bölgesinin belirlenmesi gerekmektedir. Kalp bölgesi Şekil 4.7'de de görüldüğü üzere sol iriste saat 2 ile 4 konumları arasında yer almaktadır. Dairesel iris görüntüsü normalizasyon işlemi sonucunda sabit boyutlu dikdörtgene dönüştürüldükten sonra iristeki kalp bölgesi kırpılmıştır. Bölgenin boyutları 190×120 pikseldir. Kırpılan bölge öznitelik çıkarma işlemi öncesinde dokusal parametrelerin daha iyi gözlenebildiği görüntü iyileştirme aşamasına geçmektedir.




Şekil 4.7. Sol iristeki kalp bölgesinin konumu

4.2.4. Görüntü İyileştirme

Göz görüntüsünün öznelilik çıkarma işlemleri öncesindeki görüntü ön-işleme sürecinin son aşaması iyileştirme aşamasıdır. ROI bölgesine ait görüntünün iyileştirilmesine ait temel amaç görüntü kalitesini artırmak ve yorumlama yapılacak bilgileri daha net ortaya çıkarmaktır. İyileştirmenin genel bir yöntemi bulunmamakla birlikte yapılan uygulamaya göre değişirken; performansı da kullanıcıya bağlı olarak farklılık gösterebilmektedir.

Görüntü iyileştirme, görüntüdeki gürültüyü azaltmak, kontrastı artırmak, netliği iyileştirmek veya renk düzeltmeleri gibi farklı hedeflere yönelik bir dizi işlemi kapsamaktadır. Bu bağlamda Kontrast Sınırlı Adaptif Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization, CLAHE) kontrastı düzenlemek için görüntünün histogramını analiz eden bir görüntü iyileştirme tekniğidir. CLAHE yöntemi, görüntünün belirli bir bölgesini alır ve bu bölge üzerinde histogram eşitleme işlemi uygular. Ancak, genel histogram eşitleme yönteminden farklı olarak, CLAHE, lokal kontrastı artırmak için adaptif bir yaklaşım kullanır. Bu adaptif yaklaşım, görüntünün farklı bölgelerindeki kontrast farklılıklarını dikkate alarak bölgesel kontrastı artırır. Yöntemde her bir bölgenin histogramı belirli bir yoğunluk değerine sınırlanmaktadır (Fu vd., 2019; Zheng vd., 2016). Bu maksimum sınırlaması gürültü artışını önlemeye yardımcı olmaktadır. Şekil 4.8’de histogram eşitlendiği ve CLAHE yönteminin uygulandığı örnek bir görüntü yer almaktadır.



Şekil 4.8. Örnek bir ROI bölgesi görüntüsü için (a) Orijinal görüntü ve histogramı (b) Histogramı eşitlemiş görüntü ve histogramı (c) CLAHE yöntemi sonucundaki görüntü ve histogramı

4.3. Öznitelik Çıkarma

İrsten öznitelik çıkarmak için çeşitli yöntemler kullanılmaktadır. Bu başlık altında tez çalışmasında kullanılan yöntemlere yer verilmiştir.

4.3.1. Ayırık Dalgacık Dönüşümü

Sınıflandırma amaçlı dokusal parametreleri elde etmek için Ayırık Dalgacık dönüşümü (Discrete Wavelet Transform, DWT) sıklıkla kullanılmaktadır. Yöntemde görüntü alçak geçiren ve yüksek geçiren iki filtre vasıtasıyla alt görüntülere ayrılmaktadır. Dönüşüme ait matematiksel ifadeler aşağıdaki gibidir.

$$A_n = \left[H_x * [H_y * A_{n-1}]_{\uparrow 2,1} \right]_{\downarrow 1,2} \quad (4.5)$$

$$H_n = \left[H_x * [G_y * A_{n-1}]_{\uparrow 2,1} \right]_{\downarrow 1,2} \quad (4.6)$$


$$V_n = \left[G_x * [H_y * A_{n-1}]_{\uparrow 2,1} \right]_{\downarrow 1,2} \quad (4.7)$$

$$D_n = \left[G_x * [G_y * A_{n-1}]_{\uparrow 2,1} \right]_{\downarrow 1,2} \quad (4.8)$$

Denklemlerdeki $\uparrow 2,1$ ve $\downarrow 1,2$ satır ve sütun boyunca alt örnekleri temsil etmektedir. A_0 görüntü matrisini, H ve G de alçak geçiren ve bant geçiren filtreleri


göstermektedir. A_n yaklaşık görüntüsünü, H_n , V_n ve D_n ise n ölçeğindeki görüntüleri temsil etmektedir.

DWT bir görüntüyü yaklaşıklık (LL), yatay (HL), dikey (LH) ve köşegen (HH) olmak üzere dört alt-örneklenmiş görüntüye ayırır. $N \times N$ boyutundaki girdi görüntüsü her biri $N/2 \times N/2$ boyutunda dört alt görüntüye bölünür. Her alt görüntü farklı frekans bileşenlerinden bilgi içermektedir (Diwakar vd., 2021). Şekil 4.9’da 1 seviye DWT ayrıştırmasına ait işlem gösterilmektedir.



Şekil 4.9. 1-Seviye DWT ayrışması

Burada, LL alt bandı, hem satırlar hem de sütunlara uygulanan alçak geçiren filtreleme ile elde edilir ve diğer alt bantlara göre daha az gürültünün olduğu görüntüdür. HH bandı her iki yönde yüksek geçiren filtreleme ile elde edilir ve diğer bantlara göre yüksek frekans bileşenlerini içerir. HL ve LH alt bantları ise bir yönde düşük diğer yönde yüksek filtreleme ile elde edilirler. LH daha çok yatay kenarlara karşılık gelen dikey detay bilgilerini içerirken HL ise dikey kenarlardaki yatay detay bilgilerini içerir. HL, LH ve HH alt bantları yaklaşık görüntüye yüksek frekans detayını ekledikleri için alt bantların detaylarını verir. Görüntü DWT ile genellikle LL bandı kullanılarak birden fazla ayrıştırılır (Kumar ve Singh, 2021). Şekil 4.10’da n -Seviye ayrıştırma için blok diyagram yer almaktadır.



Şekil 4.10. n-Seviye DWT ayrışması

DWT’de Haar, Daubechies ve Symlet dalgacıkları çeşitli sinyal ve görüntü işleme uygulamalarında sıklıkla kullanılmaktadır (Panja vd., 2019). Symlet dalgacıkları, simetrik bir şekle sahip olan ve diğer dalgacıklar ile karşılaştırıldığında keskin geçişli sinyalleri analiz etmek için daha uygun olan bir dalgacık türü olduğundan bu çalışmada tercih edilen dalgacık modelidir (Zaeni vd., 2018).

4.3.2. Birinci Dereceden İstatistiksel Analizler

Görüntü içerisinde birinci dereceden istatistikler görüntüyü tanımlamak ve özelliklerini ölçmek için kullanılır. Bu istatistikler, görüntüdeki her bir pikselin yoğunluğunu veya parlaklığını temsil eder ve görüntünün genel özelliklerini anlamak için kullanılır. Bu çalışmada analiz bölgesinden beş farklı birinci dereceden istatistiksel özellik hesaplanmış ve kullanılmıştır. Bunlar sırasıyla ortalama yoğunluk, standart sapma, entropi, çarpıklık ve basıklıktır. Gri seviye ROI'den elde edilen bu parametrelerin matematiksel ifadeleri ve açıklamaları aşağıdaki gibidir. Formüllerdeki N ; gri seviyeleri ve X ise ROI görüntüsünü ifade etmektedir.

Ortalama Yoğunluk (Mean Intensity, MI): Bir görüntüdeki tüm piksel yoğunluklarının toplanması ile elde edilen toplam yoğunluğun piksel sayısına bölünmesiyle hesaplanır. Bu parametre, görüntüdeki ortalama parlaklık düzeyini ölçer ve birinci dereceden istatistiksel bir parametre olarak kullanılır. Bir görüntünün ortalama yoğunluğu, görüntünün genel parlaklık düzeyini temsil etmektedir. Bu kavram görüntü işleme ve analizlerinde sıkça kullanılan bir ölçüdür.

$$MI = \frac{1}{N} \sum_{i=1}^N X(i) \quad (4.10)$$

Standart Sapma (Standard Deviation, SD): Bir görüntünün piksel yoğunluk dağılımının ölçüsüdür ve bu dağılımın ne kadar yaygın olduğunu belirler. Düşük

standart sapma, yoğunluk değerlerinin ortalamaya yakın olduğu bir dağılımı ifade ederken; yüksek standart sapma, yoğunluk değerlerinin daha geniş bir aralıkta değiştiği ve ortalamadan daha uzakta olduğu bir dağılımı ifade eder.

$$SD = \left(\frac{1}{N-1} \sum_{i=1}^N (X(i) - \bar{X})^2 \right)^{1/2} \quad (4.11)$$

Entropi (Entropy, Ent1): Bir görüntünün düzenliliğini ölçen bir parametredir. Görüntünün piksel yoğunluklarındaki düzensizlik seviyesini gösterir. Görüntünün homojen veya düzensiz bölgelerini belirlemek için kullanılabilir. Yüksek entropi, görüntüdeki farklılıkların daha fazla olduğu ve düzensizliğin daha yüksek olduğu bir bölgeyi ifade ederken; düşük entropi, homojen bölgeleri ve düzenliliği ifade eder.

$$Ent1 = \sum_{i=1}^{N_1} P(i) \cdot \log_2 P(i) \quad (4.12)$$

Çarpıklık (Skewness, Sk): Bir dağılımın ortalama değerine göre simetrisinden ne kadar sapma olduğunu ölçen bir parametredir. Bir dağılımın çarpıklığı, dağılımın sağa veya sola doğru ne kadar çarpıldığını gösterir. Pozitif çarpıklık, dağılımın sağa doğru çarpıldığını gösterirken; negatif çarpıklık, dağılımın sola doğru çarpıldığını gösterir. Eğer çarpıklık sıfıra yakınsa, o zaman dağılımın simetrik olduğu anlaşılır.

$$Sk = \frac{\frac{1}{N} \sum_{i=1}^N (X(i) - \bar{X})^3}{\left(\sqrt{\frac{1}{N} \sum_{i=1}^N (X(i) - \bar{X})^2} \right)^3} \quad (4.13)$$


Basıklık (Kurtosis, Ku): Gri tonların dağılımının ortalama etrafında daha fazla yayılma ya da yoğun olma durumunu tanımlayan bir parametredir. Bir dağılımın veri noktalarının ağırlıklı olarak orta veya kuyruk kısmında olma durumu hakkında bilgi verir. Normal bir dağılımda, basıklık 3'e eşittir. Eğer basıklık 3'ten büyükse, bu, dağılımın normalden daha basık olduğunu gösterir. Eğer basıklık 3'ten küçükse, bu, dağılımın normalden daha sivri olduğunu gösterir.

$$Ku = \frac{\frac{1}{N} \sum_{i=1}^N (X(i) - \bar{X})^4}{\left(\frac{1}{N} \sum_{i=1}^N (X(i) - \bar{X})^2 \right)^2} \quad (4.14)$$


4.3.3. Gri Seviye Eş-oluşum Matrisi (GLCM)

Sadece birinci dereceden istatistiksel yaklaşımları kullanmak, bir görüntüdeki dokuları veya desenleri tespit etmek ve derecelendirmek için yetersizdir. Bu özellikler sadece yoğunluk dağılımı hakkında bilgi verir ancak pikseller arasındaki ilişkiyi ortaya çıkarmaz. Komşu pikseller hakkında bilgi edinmek için (Haralick vd., 1973) tarafından önerilen GLCM ve ilgili özellikler kullanılabilir. GLCM, gri seviye yoğunluklarının dağılımını karakterize eden, ölçen ve araştıran bir gri seviye matrisidir. GLCM hesaplanırken yön ve komşuluk bilgileri kullanılır. Şekil 4.11’de görüldüğü gibi 0°, 45°, 90° ve 135° yönleri kullanılmaktadır. GLCM oluşturulurken görüntüdeki her bir pikselin gri tonlama değeri (4.15) eşitliğindeki gibi hesaplanmaktadır. Şekil 4.12’de GLCM matrisinin oluşturulmasına ait bir örnek yer almaktadır.

$$P(i, j) = \frac{P(i, j, d, \theta)}{\sum_{i=1} \sum_{j=1} P(i, j, d, \theta)} \quad (4.15)$$



Şekil 4.11. Komşu piksel analizi için yön bilgisi



Şekil 4.12. Bir piksel komşuluk ve 0° yönlü GLCM matrisinin oluşturulması

Görüntünün GLCM'si oluşturulduktan sonra görüntünün dokusal özellikleri bu matristen çıkarılır. Bu çalışmada GLCM kullanarak özellik çıkarmak için 22 parametre (Clausi, 2002; Haralick vd., 1973; Soh ve Tsatsoulis, 1999) kullanılmıştır. Bu parametrelerin isimleri, matematiksel ifadeleri ve tanımları aşağıda verilmektedir. Formüllerdeki $P(i,j)$; GLCM matrisini, i ve j ; matrisin satır ve sütunlarını, μ ; ortalama değeri, σ ; varyansı, N ; gri seviye sayısını ve H ise korelasyon bilgisini ifade etmektedir.

Otokorelasyon (Auto Correlation, AC): Bir görüntünün pürüzlülüğünü ölçer ve doku pikselleri arasındaki doğrusal uzamsal ilişkileri değerlendirir. Yüksek bir otokorelasyon değeri, bir görüntüdeki piksellerin benzer gri seviye değerlerine sahip olduğunu gösterirken, düşük bir değer piksellerin benzer olmayan gri seviye değerlerine sahip olduğunu gösterir.

$$AC = \sum_{i=1}^N \sum_{j=1}^N (i \cdot j) p(i, j) \quad (4.16)$$

Küme belirginliği (Cluster Prominence, CP): Bir asimetri ölçüsüdür. Yüksek bir CP değeri kümedeki piksellerin gri seviye değerlerinde yüksek derecede varyasyona sahip olduğunu, yani kümenin dağınık olduğunu gösterirken, düşük bir değer piksellerin düşük derecede varyasyona sahip olduğunu, yani kümenin kompakt olduğunu gösterir.

$$CP = \sum_{i=1}^N \sum_{j=1}^N (i + j - 2u)^3 p(i, j) \quad (4.17)$$

Küme Gölgesi (Cluster Shade, CS): Matrisin çarpıklığını ölçen ve birliktelik kavramlarının algısal özelliklerini değerlendiren bir ölçüttür. Yüksek bir CS değeri, kümelerdeki piksellerin gri seviye değerlerinde yüksek derecede varyasyon olduğunu gösterir; ve bu da kümelerin yoğunlukta güçlü bir değişkenlik gösterdiğini göstermektedir. Düşük bir değer ise, piksellerin düşük derecede varyasyon gösterdiğini gösterir, bu da kümenin yoğunlukta zayıf bir değişkenlik gösterdiğini ortaya koymaktadır.

$$CS = \sum_{i=1}^N \sum_{j=1}^N (i + j - 2u)^4 p(i, j) \quad (4.18)$$

Kontrast (Contrast, Con): Bir görüntünün farklı bölgelerindeki piksel değerleri arasındaki farklılıkları ölçmek için kullanılır. Referans piksel ve komşusu arasındaki yoğunluk veya griseviye değişim ölçüsüdür. Bu özellik bir görüntünün kenarlarını veya kenar benzeri özelliklerini belirlemek için kullanılabilir.

$$Con = \sum_{i=1}^N \sum_{j=1}^N (i - j)^2 p(i, j) \quad (4.19)$$

Korelasyon (Correlation, Cor): GLCM'deki gri seviye değerlerinin doğrusal bağımlılığını ölçer veya GLCM'nin satırları ve sütunları arasındaki korelasyonları tanımlar. Yüksek bir korelasyon değeri piksellerin gri seviye değerleri arasında güçlü bir doğrusal ilişki olduğunu gösterirken, düşük bir değer piksellerin zayıf bir doğrusal ilişkiye sahip olduğunu veya hiç olmadığını gösterir.

$$Cor = \sum_{i=1}^N \sum_{j=1}^N \left(\frac{i - \mu_x}{\sigma_x} \right) \left(\frac{j - \mu_y}{\sigma_y} \right) p(i, j) \quad (4.20)$$

Fark Entropisi (Difference Entropy, DE): Bir görüntüdeki iki pikselin gri seviye değerlerinin birbirlerine göre ne kadar rastgele veya belirsiz olduğunun bir ölçüsüdür. Yüksek bir fark entropi değeri piksellerin gri seviye değerlerinde yüksek derecede rastgelelik veya belirsizlik olduğunu gösterirken, düşük bir değer piksellerin düşük derecede rastgelelik veya kesinliğe sahip olduğunu gösterir.

$$DE = - \sum_{k=0}^{N-1} p_{x-y}(k) \log p_{x-y}(k) \quad (4.21)$$

Fark Varyansı (Difference Variance, DV): Yerel değişkenliğin bir ölçüsüdür. Yüksek bir fark varyansı değeri, piksellerin gri seviye değerlerinde yüksek derecede değişkenliğe sahip olduğunu gösterirken, düşük bir değer piksellerin düşük derecede değişkenliğe sahip olduğunu gösterir.

$$DV = \sum_{k=0}^{N-1} (k - \mu_{x-y})^2 p_{x-y}(k) \quad (4.22)$$

Benzeşmezlik (Dissimilarity, Dis): Bir görüntüdeki gri seviye çiftlerinin değişimini tanımlayan bir ölçüdür. Bu özellik, ağırlık farkı ile kontrasta en yakındır.

Kontrastın benzemezlikten farkı ikinci dereceden büyümesidir. Bu iki ölçümün aynı dokuda aynı şekilde davranması beklenir çünkü aynı parametreyi farklı ağırlıklarda hesaplarlar. Kontrast her zaman benzerlikten biraz daha yüksek değerler verecektir. Benzerlik [0, 1] arasında değişir ve referans ve komşu pikselin gri seviyesi olası gri seviyenin uç noktalarında olduğunda maksimuma ulaşır.

$$Dis = \sum_{i=1}^N \sum_{j=1}^N |i - j| \cdot p(i, j) \quad (4.23)$$

Enerji (Energy, E): Enerji, bir görüntüdeki iki pikselin gri seviye değerlerinin ne kadar homojen veya tekdüze olduğunun bir ölçüsüdür. Yüksek bir enerji değeri piksellerin gri seviye değerlerinde yüksek derecede homojenlik veya tekdüzelik olduğunu gösterirken, düşük bir değer piksellerin düşük derecede homojenlik veya tekdüzelik olduğunu gösterir.

$$E = \sum_{i=1}^N \sum_{j=1}^N p(i, j)^2 \quad (4.24)$$

Entropi (Entropy, Ent2): Düzensiz bir GLCM için düşük değer üreten bir rastgelelik tanımlayıcısıdır. Yüksek bir entropi değeri, piksellerin gri seviye değerlerinde yüksek derecede rastgelelik veya belirsizlik olduğunu gösterirken, düşük bir değer piksellerin düşük derecede rastgelelik veya kesinliğe sahip olduğunu gösterir.

$$Ent2 = - \sum_{i=1}^N \sum_{j=1}^N p(i, j) \log p(i, j) \quad (4.25)$$

Homojenlik (Homogeneity, Hom): GLCM'deki öğelerin dağılımının GLCM diyagonaline yakınlığını ölçer. Yüksek bir homojenlik değeri piksellerin gri seviye değerlerinde yüksek derecede benzerlik veya tekdüzelik olduğunu gösterirken, düşük bir değer piksellerin düşük derecede benzerlik veya tekdüzelik olduğunu gösterir.

$$Hom = \sum_{i=1}^N \sum_{j=1}^N \frac{p(i, j)}{1 + (i - j)^2} \quad (4.26)$$

Korelasyon Bilgisi Ölçüm 1 (Informational Measure of Correlation 1, IMC1): IMC1, görüntüdeki iki pikselin gri seviye değerlerinin ne kadar birbirleriyle ilişkili

olduğunun ölçüsüdür. IMC1 değeri yüksek olan piksel çiftleri, gri seviye değerleri arasında yüksek bir korelasyona sahipken, düşük bir IMC1 değeri piksellerin gri seviye değerleri arasında düşük bir korelasyona sahip olduğunu gösterir.

$$IMC1 = \frac{HXY - HXY1}{\max(HX, HY)} \quad (4.27)$$

Korelasyon Bilgisi Ölçüm 2 (Informational Measure of Correlation 2, IMC2): IMC2, iki pikselin gri seviye değerleri arasındaki ilişkiyi ölçen bir parametredir. IMC2 değeri yüksek olan piksel çiftleri arasındaki ilişki güçlü iken, düşük IMC2 değeri pikseller arasındaki ilişkinin zayıf olduğunu gösterir.

$$IMC2 = \sqrt{1 - \exp[-2(HXY2 - HXY)]} \quad (4.28)$$

Ters Fark Momenti (Inverse Difference Moment, IDM): Genellikle homojenlik olarak adlandırılır ve görüntünün yerel homojenliğini ölçer. Yüksek bir Ters Fark değeri, piksellerin gri seviye değerlerinde yüksek derecede benzerliğe sahip olduğunu gösterirken, düşük bir değer piksellerin düşük derecede benzerliğe sahip olduğunu gösterir.

$$IDM = \sum_{i=1}^N \sum_{j=1}^N \frac{p(i, j)}{1 + |i - j|} \quad (4.29)$$

Maksimum Olasılık (Maximum Probability, MP): Bir görüntüdeki en yüksek gri seviye olasılığını temsil eder. GLCM matrisindeki en yüksek olasılık değeri bulunarak hesaplanan MP, bir görüntüdeki en sık gri seviyenin ölçüsüdür. MP değeri ne kadar yüksekse, görüntüde en sık görülen gri seviye o kadar baskındır. Bu özellik, bir görüntüdeki en baskın gri seviyeyi tespit etmek için kullanılabilir ve bu da nesne tanıma, tıbbi görüntüleme ve uzaktan algılama gibi çeşitli görüntü işleme uygulamalarında yararlı olabilir. Ayrıca, örneğin görüntünün kontrastını artırarak en sık görülen gri seviyeyi daha görünür hale getirerek görüntü iyileştirme uygulamalarında da kullanılabilir.

$$MP = \max_{i,j} p(i, j) \quad (4.30)$$

Toplam Ortalama (Sum Average, SA): Görüntüdeki gri seviye ortalamasını sağlar. Görüntünün gri seviye toplamı yüksekse, toplam ortalamanın da büyük olması

beklenir. Sum Avarage, bir görüntüdeki açık ve yoğun alanlar arasındaki ilişkinin bir ölçüsüdür.

$$SA = \sum_{k=2}^{2N} kp_{x+y}(k) \quad (4.31)$$

Toplam Entropi (Sum Entropy, SE): Bir görüntüdeki mikro (yerel) farklılıkların toplamının bir ölçüsüdür.

$$SE = - \sum_{k=2}^{2N} p_{x+y}(k) \log p_{x+y}(k) \quad (4.32)$$

Kareler Toplamı (Sum of squares, SS): Referans ve komşu piksel değer kombinasyonlarının ortalama etrafındaki dağılımının bir ölçüsüdür. Entropiye benzer.

$$SS = \sum_{i=1}^N \sum_{j=1}^N p(i - \mu)^2 p(i, j) \quad (4.33)$$

Toplam Varyans (Sum Variance, SV): Bir görüntünün uzamsal heterojenliğini (benzemezliğini) ortaya çıkarır.

$$SV = \sum_{k=2}^{2N} (k - \mu_{x+y})^2 p_{x+y}(k) \quad (4.34)$$

Maksimum Korelasyon Katsayısı (Maximal Correlation Coefficient, MCC): Q tarafından nicemlenen bir görüntüdeki farklı gri seviyelerin sayısıdır.

$$MCC = \sqrt{\lambda_2(Q(i, j))} \quad (4.35)$$


(Inverse difference normalized, IDN ve Inverse difference moment normalized, IDMN): Gri seviye çiftlerinin küçük gri ton farklılıkları için daha büyük değerleri dikkate alarak görüntü homojenliğini ölçer. GLCM'deki diyagonal elemanların varlığına daha duyarlıdır. Görüntüdeki tüm öğeler aynı olduğunda maksimum değere sahiptir.

$$IDN = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{1}{1 + (i - j)^2} p(i, j) \quad (4.36)$$

$$IDMN = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{p(i, j)}{\left(1 + \frac{|i - j|}{N}\right)^2} \quad (4.37)$$

4.3.4. Gri Seviye Koşu Uzunluğu Matrisi (GLRLM)

Gri Seviye Koşu Uzunluğu Matrisi (GLRLM) yöntemi, farklı gri seviye uzunluklarının sayısının hesaplanmasına dayanır (Haralick vd., 1973). Daha yüksek dereceli istatistiksel doku özelliklerini çıkarmanın bir yoludur. Bir gri seviye koşusu, aynı gri seviye değerine sahip bitişik görüntü noktalarının doğrusal bir dizisidir. Gri seviye çalışma uzunluğu, dizideki görüntü noktalarının sayısıdır. GLRLM iki boyutlu bir matristir ve doku özelliği çıkarımı için kullanılır. Şekil 4.13'te GLRLM matrisinin oluşturulmasına ait örnek verilmektedir.



Şekil 4.13. 0° yönlü GLRLM matrisinin oluşturulması

Bu çalışmada ele alınan GLRLM'nin temel alındığı yedi öz niteliğe, isimlerine, matematiksel eşitliklerine ve açıklamalarına aşağıda yer verilmiştir. Formüllerdeki $P(i, j | \theta)$; θ yönlü GLRLM matrisini, i ve j ise matrisin satır ve sütunlarını, R ; koşu uzunluğu ve G de görüntüdeki yoğunluk değerlerinin sayısını ifade etmektedir.

Kısa Koşu Vurgusu (Short Run Emphasis, SRE): Kısa koşuların dağılımını ölçer. Kısa çalışma uzunlukları, her çalışma uzunluğu değerinin uzunluğunun karesine bölünmesiyle vurgulanır. SRE, kısa koşuların oluşumuna büyük ölçüde bağlıdır ve ince dokular için büyük olması beklenir.

$$SRE = \frac{\sum_{i=1}^G \sum_{j=1}^R \frac{p(i,j|\theta)}{j^2}}{\sum_{i=1}^G \sum_{j=1}^R \frac{p(i,j|\theta)}{1}} \quad (4.38)$$

Uzun Koşu Vurgusu (Long Run Emphasis, LRE): Uzun koşuların dağılımını ölçer. Her bir çalışma uzunluğu değeri, uzunluğunun karesi ile çarpılarak daha uzun çalışmalara daha fazla ağırlık verilir. LRE, uzun koşuların oluşumuna büyük ölçüde bağlıdır ve kaba dokular için büyük olması beklenir.

$$LRE = \frac{\sum_{i=1}^G \sum_{j=1}^R j^2 \times p(i,j|\theta)}{\sum_{j=1}^R p(i,j|\theta)} \quad (4.39)$$

Gri Seviye Tekdüzeliliği (Gray Level Non-Uniformity, GLN): Görüntü boyunca gri seviye değerlerinin benzerliğini ölçer. Yüksek çalışma uzunluğu değerleri bu özelliğe en fazla katkıda bulunacaktır. Çalışmalar tüm gri düzeylere eşit olarak dağıtılmışsa GLN özelliği en düşük değere sahip olacaktır. Gri seviye değerleri görüntü boyunca benzer ise GLN özelliğinin küçük olması beklenir.

$$GLN = \frac{\sum_{i=1}^G (\sum_{j=1}^R p(i,j|\theta))^2}{\sum_{i=1}^G \sum_{j=1}^R p(i,j|\theta)} \quad (4.40)$$

Koşu Yüzdesi (Run Percentage, RP): Tüm koşuların uzunluğu 1 ise, görüntüdeki gözlemlenen koşuların toplam sayısı ile olası koşuların toplam sayısı arasındaki orandır. Bir görüntünün belirli bir yöndeki koşu dağılımını ve homojenliğini ölçer. Belirli bir yöndeki her gri seviye için çalışma uzunluğu 1 olduğunda RP özelliği en yüksek seviyededir.

$$RP = \frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R p(i,j|\theta) \quad (4.41)$$

Koşu Uzunluğu Tekdüzeliliği (Run Length Non-Uniformity, RLN): Görüntü genelinde koşu uzunluklarının benzerliğini ölçer. Koşular tüm koşu uzunluklarına eşit olarak dağıtılmışsa, RLN özelliği en düşük değere sahip olacaktır. Görüntüdeki koşu uzunlukları birbirine benziyorsa, RLN özelliğinin düşük olması beklenir.

$$RLN = \frac{\sum_{j=1}^R (\sum_{i=1}^G p(i, j|\theta))^2}{\sum_{i=1}^G \sum_{j=1}^R p(i, j|\theta)} \quad (4.42)$$

Düşük Gri Seviye Koşu Vurgulama (Low Gray Level Run Emphasis, LGRE):

Düşük gri seviye değerlerinin dağılımını ölçer. Düşük gri değerli görüntü için LGRE'nin yüksek olması beklenir.

$$LGRE = \frac{\sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|\theta)}{i^2}}{\sum_{i=1}^G \sum_{j=1}^R p(i, j|\theta)} \quad (4.43)$$

Yüksek Gri Seviye Koşu Vurgulama (High Gray Level Run Emphasis, HGRE):

Yüksek gri seviye değerlerinin dağılımını ölçer. Yüksek gri seviyeli bir görüntü için HGRE özelliğinin yüksek olması beklenir.

$$HGRE = \frac{\sum_{i=1}^G \sum_{j=1}^R i^2 \times p(i, j|\theta)}{\sum_{i=1}^G \sum_{j=1}^R p(i, j|\theta)} \quad (4.44)$$

4.4. Öznitelik Seçme İşlemi

Öznitelik seçme işlemi sınıflandırma problemlerinde makine öğrenmesi yöntemlerinde karmaşıklığı azaltma ve zaman tasarrufu için önemli bir adımdır. Gereksiz verileri ayrıştırarak sınıflandırmanın daha güvenilir olmasını sağlamaktadır. Bu tez çalışmasında ReliefF yöntemi öznitelik seçme için tercih edilmiştir.

ReliefF öznitelik seçme yöntemi filtre tabanlı ve yaygın olarak kullanılan bir öznitelik seçme yöntemidir. Kira ve Rendell tarafından geliştirilen Relief algoritması parametreler arasında ilişkiye göre ağırlıklandırma yaparak seçim işlemi gerçekleştirir (Kira ve Rendell, 1992). Bu yöntem çoklu sınıfları barındıran veri setlerinde başarılı sonuç vermemesinden dolayı Kononenko tarafından ReliefF algoritması geliştirilmiştir (Kononenko, 1994). ReliefF metodu veri setinden bir örnek ele alarak ilgili örneğin, kendi sınıflarındaki diğer örneklerle yakınlığına ve farklı sınıflarla olan uzaklığına bağlı bir model oluşturarak öznitelik seçme işlemini gerçekleştirmektedir. Algoritma, öncelikle her bir öznitelik için seçilecek en yakın komşu sayısı anlamına gelen k sayısını belirler. Rastgele seçilen bir örneğin sınıf etiketine bakılarak kaydedilir. Seçilen örneğe en yakın k komşusu belirlenerek komşuların uzaklıklarına ait ağırlık bilgileri hesaplanır. Tüm komşu örneklerle ait ağırlıklar toplanarak kaydedilir ve önem ölçüsü hesaplanır. Süreç k sayısı kadar devam ederek önem ölçüsü

değerleri güncellenir. Tüm öznitelikler için önem ölçüsü değerleri hesaplanır. En yüksek önem ölçüsü değerine sahip olanlar veri setini temsil etmek için belirlenerek kullanılmaktadır.

4.5. Sınıflandırma

Sınıflandırma, verileri özelliklerine göre farklı sınıflara veya kategorilere ayırmayı içeren makine öğrenimi için temel bir kavramdır. Sınıflandırmada etiketli eğitim verilerinden öğrenilen kalıplara ve bilgilere dayanarak yeni, görülmemiş örneklerle doğru bir şekilde etiket atayabilen bir model veya algoritma geliştirmek amaçlanmaktadır. Sınıflandırma amaçlı yaygın bir şekilde kullanılan makine öğrenmesi algoritmaları, denetimli ve denetimsiz olarak iki kategoriye ayrılmaktadır. Denetimli sınıflandırmada, öğrenme sürecinde daha önce değeri ya da sınıfı bilinen etiketli veriler kullanılırken; denetimsiz sınıflandırmada etiketsiz veriler kullanılmaktadır. Bu çalışmada literatürde yaygın bir şekilde kullanılan ve denetimli makine öğrenmesi yöntemlerinden olan Naive Bayes, Karar Ağaçları, K- En Yakın Komşu, Destek Vektör Makineleri ve Yapay Sinir Ağları sınıflandırıcıları kullanılmıştır. Kullanılan sınıflandırma yöntemleri aşağıdaki alt başlıklarda açıklanmaktadır.

4.5.1. Naive Bayes (NB)

Naive Bayes algoritması, İngiliz matematikçi Thomas Bayes tarafından geliştirilen Bayes teoremi temeline dayanan ve istatistiksel sınıflandırma problemlerini çözmek için kullanılan basit ve etkili bir makine öğrenimi yöntemidir. Yöntem, verilerin belirli bir sınıfa ait olma olasılığını hesaplar ve bu olasılıkları kullanarak en uygun sınıflandırmayı belirler. NB algoritması, verilerin arasındaki her özelliğin birbirinden bağımsız olduğu varsaydığı için "naive" (saf) olarak adlandırılır. Bu varsayım, algoritmanın hesaplamalarını basitleştirir ve işlem süresini azaltır. Sınıflandırma sürecinde Bayes teoreminden yararlanılarak, bir veri örneğinin belli bir sınıfa ait olma olasılığı hesaplanır (Rish, 2001).

Örneğin, veri örneği $X = (X_1, X_2, \dots, X_n)$ olsun. Bu veri örneğinin sınıfını belirlemek için, her sınıf C için sınıfın koşullu olasılığı $P(C|X)$ hesaplanır. $P(C|X)$, veri örneğinin özellikleri $X_1, X_2, \dots, X_n$ verildiğinde, örnek X 'in sınıfı C olma olasılığıdır.

$P(c|x)$ hesaplamak için kullanılan Bayes teoremi ifadesi denklem 4.45'teki gibidir.


$$P(C|X) = P(X|C) \times P(C)/P(X) \quad (4.45)$$

Burada, $P(X|C)$ verilen sınıfta x örneği için gözlemlenen özelliklerin olasılığıdır. $P(C)$ sınıfın apriori olasılığıdır ve veri kümesindeki örneklerin sınıflandırma dağılımından hesaplanır. $P(X)$ ise verilen örneğin olasılığıdır ve tüm sınıflar için ayrı ayrı hesaplanır.

NB algoritması, sınıflandırma için en yüksek olasılığa sahip sınıfı seçmektedir. Bu yöntem, veri kümeleri üzerinde yüksek doğruluk oranları sağlamakta ve hızlı hesaplama süresi nedeniyle büyük veri kümeleri üzerinde de etkili bir şekilde tercih edilmektedir (Webb vd., 2010).

4.5.2. Karar Ağaçları (DT)

Karar Ağaçları algoritması, veri kümesindeki parametrelerden yola çıkarak düğümler halinde bir karar verme prosedürünün olduğu ağaç yapısını kullanarak sınıflandırma ve regresyon problemlerinin çözümünde kullanılan makine öğrenmesi yöntemidir. Algoritma, veri kümesini bir dizi karar kuralı veya koşul ile böler ve bu kararlar üzerinden sınıflandırma veya regresyon işlemini gerçekleştirir. Şekil 4.14'te basit yapıda bir karar ağaç görselinde belirttiği gibi ağaç yapısı; düğümler, yapraklar ve dallar olmak üzere üç temel bölümden oluşmaktadır. Düğümler, ağacın iç kısmında yer alarak alt düğümlerle bağlantılıdır ve veri kümesindeki bir özelliği temsil etmektedirler. Yapraklar, ağacın alt kısımlarında yer alırlar ve sınıflandırma veya regresyon sonuçlarını temsil ederler. Dallar ise düğümleri birbirine bağlayan ve veri kümesini belirli koşullara göre bölen bağlantıları ifade etmektedir. Bir düğümdeki koşulun doğru veya yanlış sonucuna bağlı olarak dalların takip ettiği yol belirlenir ve bu yol, veri noktalarının hangi alt kümeye yönlendirileceğini belirler (Che vd., 2011; Kozak, 2019).



Şekil 4.14. Örnek bir karar ağacı


Özellik seçimi, karar ağacının en iyi bölme noktalarını belirlemek için önemli bir aşamadır. Bilgi kazancı (information gain), Gini safsızlığı (impurity) veya Hata Karesi gibi ölçütlerin kullanılmasıyla özelliklerin önemi değerlendirilerek en iyi ayrımı sağlayan özellikler seçilmesi sağlanmaktadır. Ağacın büyüklüğünün belirlenmesi de özellik seçimi gibi büyük öneme sahiptir. Çok büyük bir ağaç, aşırı uyum (overfitting) durumuna yol açabileceğinden, büyüklüğü kontrol etmek için gereksiz dalların ve yaprakların kaldırılmasını içeren budama adı verilen bir yöntem kullanılmaktadır (Grabmeier ve Lambe, 2007; Tangirala, 2020).

Karar ağaçlarının oluşturulması için çeşitli yöntemler kullanılmaktadır. ID3 (Iterative Dichotomiser 3) metodu, bilgi kazancı yöntemini kullanarak en iyi bölme kriterini belirlemektedir. Her düğümdeki özelliğin veri kümesindeki bilgi kazancını maksimize etmeye çalışmaktadır. C4.5 algoritması ID3'ün geliştirilmiş bir versiyonu olup ID3'ten farklı olarak sayısal veriler işlenebilmektedir. C4.5 ayrıca karar ağacının büyüklüğünü kontrol etmek için budama sürecini de içermektedir. CART (Classification and Regression Trees) ise "Gini impurity" veya "Hata Karesi" ölçütlerini kullanarak en iyi bölme noktasını belirlemektedir. Bu yöntemde de budama işlemi yer almaktadır (Dai ve Ji, 2014; Jin vd., 2009; Singh ve Gupta, 2014).

4.5.3. k-En Yakın Komşu (k-NN)

k-En Yakın Komşu (k-Nearest Neighbors, k-NN) algoritması, sınıflandırma ve regresyon amaçlı sıklıkla kullanılan bir makine öğrenmesi algoritmasıdır. Örneklerin bir eğitim veri kümesindeki mevcut örneklerle benzerliğine göre sınıflandırıldığı bir öğrenme metodudur. Algoritmanın çalışma prensibi tahmin edilecek olan örneğin eğitim verileri içerisindeki en yakın k komşu arasındaki mesafeyi hesaplamasına dayanmaktadır. Tahmin edilecek veri en kısa mesafeye sahip k komşunun değerine bakarak belirlenir. Sınıflandırma problemlerinde verinin sınıf etiketi, k komşunun sınıflarının oy çokluğu alınması ile belirlenmektedir. k-NN sınıflandırıcısı parametrik olmayan bir yöntemdir, yani verilerin temel dağılımı hakkında herhangi bir varsayımda bulunmamaktadır. Sayısal, kategorik ve karışık veriler de dahil olmak üzere her tür veriyle çalışabilmektedir (Liao ve Vemuri, 2002).

Sınıflandırma işleminin doğruluğunu etkileyebilecek parametrelerden bir tanesi k değerinin seçimidir. Küçük bir k değeri, modelin çok karmaşık hale geldiği ve verilerdeki gürültüye uyduğu aşırı uyuma neden olabileceği gibi büyük k değeri, modelin basitleştirilmesine ve yetersiz uyuma neden olabilmektedir. Şekil 4.15'te iki farklı sınıfa ait örnek bir veri dağılımı yer almaktadır. Şekilde sarı renkli veriler birinci sınıfı, mor renkli veriler ikinci sınıfı göstermekte ve kırmızı renkli veri ise sınıf değerinin tahmin edileceği veriyi göstermektedir. Kırmızı renkli verinin etrafında $k=3$ ve $k=6$ için çizgili daire yer almaktadır. k değerinin 3 olması verinin ikinci sınıfa ait olacağını belirtirken, k değerinin 6 olması verinin birinci sınıfa ait olacağını belirtmektedir (Abu Alfeilat vd., 2019; Hassanat vd., 2014).



Şekil 4.15. k-NN sınıflandırıcısı için iki farklı sınıfa ait örnek bir veri dağılımı (José, 2018)

Sınıflandırma sürecinin performansını etkileyen bir başka parametre ise verilerin arasındaki mesafelerin ölçüm yöntemidir. Mesafe hesabı için en sık kullanılan ölçümler, Öklid, Manhattan ve Minkowski mesafeleridir. Öklid mesafesi, iki nokta arasındaki en kısa mesafeyi ifade eder ve iki nokta arasındaki fark vektörünün uzunluğuna eşittir. $P=(x_1,x_2,\dots,x_n)$ noktası ile $Q=(y_1,y_2,\dots,y_n)$ noktası arasındaki Öklid mesafesi Denklem 4.46'daki gibi hesaplanmaktadır (Prasatha vd., 2017).

$$\text{Öklid mesafesi} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.46)$$

Denklemde, x ve y vektörleri n -boyutlu öznitelik vektörlerini temsil etmektedir. Burada n , öznitelik sayısını ifade eder. Manhattan uzaklığı, iki nokta arasındaki farkların mutlak değerlerinin toplamını ifade etmektedir. P ve Q noktaları arasındaki Manhattan uzaklığı denklem 4.47'deki gibi hesaplanmaktadır (Prasatha vd., 2017).

$$\text{Manhattan mesafesi} = \sum_{i=1}^n |x_i - y_i| \quad (4.47)$$

Minkowski mesafesi ise Öklid ve Manhattan mesafelerinin genelleştirilmiş bir halidir. Yine P ve Q noktaları arasındaki mesafenin Minkowski ölçümüne ait matematiksel ifade Denklem 4.48'deki gibidir (Prasatha vd., 2017).


$$\text{Minkowski mesafesi} = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (4.48)$$

Denklemde yer alan p parametresi ile p 'nin farklı değerlerinde mesafe değeri de değişmektedir. p 'nin 2'ye eşit olduğu özel durumu Öklid mesafesini, p 'nin 1'e eşit olduğu değer ise Manhattan mesafesini vermektedir.

4.5.4. Destek Vektör Makineleri (SVM)

Destek vektör makineleri, 1995 yılında Vapnik tarafından geliştirilmiş, denetimli sınıflandırma problemlerini çözmek için güçlü ve yaygın olarak kullanılan bir makine öğrenmesi algoritmasıdır. SVM başlangıçta ikili sınıflandırma için geliştirilmiş bir yöntem olmakla birlikte zamanla çok sınıflı verileri sınıflandırmak için

de kullanılmaya başlanmıştır. SVM’de temel prensip bir düzlem üzerindeki iki farklı sınıfa ait veri grubunu ayıran hiperdüzlem oluşturmaya dayanmaktadır. Hiperdüzlemler iki boyutlu bir uzayda bir doğruya karşılık gelirken, üç boyutlu bir uzayda düzlem olarak ifade edilebilmektedir. Hiperdüzlem her iki sınıf verilerine de uzaklık açısından en büyük değer olmasını amaçlamaktadır (Suthaharan ve Suthaharan, 2016; Steinwart ve Christmann, 2008). Şekil 4.16’da örnek bir veri grubuna ait iki sınıflı SVM örneği yer almaktadır. Şekilde yeşil üçgenli ve kırmızı yıldızlı gösterilmek üzere iki farklı sınıfa ait veriler, destek vektörü olan veriler ve marjin bölgesi yer almaktadır. Sınıflandırma yapmak amacıyla iki sınıfı birbirinden ayıran bir doğru çizilmiştir. Bu doğrunun belirli bir mesafe uzaklığını kapsayan mavi renkli bölgeye marjin denilmektedir. Marjin alanının geniş olması sınıflandırmanın performansını da doğru orantılı olarak etkilemektedir.



Şekil 4.16. İki sınıflı örnek bir veri grubu için hiperdüzlem ve destek vektörlerinin gösterimi

Yöntem ile yeni bir örneğin tahmin edilmesine ait matematiksel ifade Denklem 4.49’daki gibidir (Lin, 2005).

$$\hat{y} = \begin{cases} \text{Sınıf A eğer } w^T \cdot x + b < 0 \\ \text{Sınıf B eğer } w^T \cdot x + b \geq 0 \end{cases} \quad (4.49)$$


Denklemden belirtilen w ; ağırlık vektörü, x ; öznitelik vektörü, b ; marjinin genişliğini belirten çizilen doğruya sapma miktarıdır. Tahmin edilecek veri, işlem sonucunda elde edilen değer sıfırdan küçükse A sınıfına, sıfırdan büyük eşit ise B sınıfına ait olacağı anlamına gelmektedir. Şekil 4.12’deki örnekte de görüldüğü üzere marjin veri noktalarını tam olarak ayrılabilir olduğu durumlarda hard marjin olarak

isimlendirilirken, marjin içerisinde de veri noktalarına izin verilen daha esnek bir sınıflandırma sağlayan durumda marjin soft marjin olarak ifade edilir (Weston ve Watkins, 1998).

Veri setinin doğrusal olarak ayrılabilir olduğu durumlarda lineer kernel fonksiyonu kullanılırken doğrusal olarak ayrılmadığı durumlarda doğrusal olmayan karar sınırlarına sahip çeşitli kernel fonksiyonları kullanılmaktadır. Yüksek dereceli polinomlarla ayrıştırılan durumlarda “Polinomial Kernel” fonksiyonu, verilerin merkez bir nokta etrafında yoğunlaştığında ve radyal baz fonksiyonları kullanılarak ayrıştırılabildiğinde “Gausiyan Radyal Temelli Kernel” fonksiyonu ve son olarak da “Sigmoid Kernel” fonksiyonu verileri ayırtmak için sıklıkla kullanılan kernel fonksiyonlarından. Sınıflandırma problemlerinde çeşitli fonksiyonlar kullanılmakla birlikte hangi kernelin seçileceği veri setine özgü olarak belirlenmektedir (Lin, 2005; Amari ve Wu, 1999).

4.5.5. Yapay Sinir Ağları (ANN)


Yapay sinir ağları, insan beyninin yapısı ve çalışma prensiplerinden esinlenerek tasarlanmış bir tür makine öğrenimi modelidir. Algoritmada, karmaşık verileri işlemek ve analiz etmek için biyolojik sinir sistemindeki nöronları taklit eden çok sayıda işlem birimlerinden oluşan ve birbirlerine bağlı düğümler yer almaktadır. ANN standart olarak içerisinde çok sayıda nöronların olduğu katmanlar halinde bir yapıdadır. Her katman, girdi verileri üzerinde belirli bir hesaplama işlemi gerçekleştirmektedir. Girdi verileri görüntü, metin, ses dosyası ve çeşitli türlerde veri türü olabilmektedir. Sinir ağlarının temel görevi girdi verilerini katmanlar sayesinde işlenerek bir çıktı ortaya koymasındır. 1957 yılında Frank Rosenblatt tarafından önerilen ve en eski sinir ağı örneği olarak gösterilen algılayıcı (perceptron) mimarisinde tek bir nöron bulunmaktadır (Dreyfus, 1990; Yegnanarayana, 2009). Bu mimariye ait örnek Şekil 4.17’deki gibidir.



Şekil 4.17. Tek nöronlu bir ANN mimarisi

Girdi verileri ($X_1, X_2, \dots, X_n$) bir dizi ağırlıkla ($W_1, W_2, \dots, W_n$) çarpılır ve bu ağırlıklı girdilerin toplamı çıktıyı üretmek için bir aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonu tipik olarak, girdinin belirli bir eşik değerini aşıp aşmadığına bağlı olarak ikili bir çıktı üreten bir adım fonksiyonudur. Ağırlıklar, perceptron öğrenme algoritması olarak bilinen bir süreç kullanılarak, tahmin edilen çıktı ile gerçek çıktı arasındaki hataya dayalı olarak eğitim sırasında güncellenir (Jain vd., 1996).

İlerleyen yıllarda tek nöronlu mimariler yerini birden fazla nöronun kullanıldığı mimarilere bırakmıştır. Girdilerin yer aldığı giriş katmanı ve çıktıların olduğu çıkış katmanları arasında ara hesaplamaların olduğu ve özelliklerin çıkarıldığı gizli katman ya da katmanların da yer aldığı çoklu katmanlı algılayıcı (Multilayer Perceptron, MLP) mimari günümüzde daha sık tercih edilmektedir (Gardner ve Dorling, 1998). Şekil 4.18’de üç katmanın yer aldığı örnek bir ANN mimarisi yer almaktadır.



Şekil 4.18. Çok katmanlı bir ANN mimarisi (Zaloğlu, 2015)

Katmanlar arasındaki her bağıntıya bir ağırlık değeri atanmaktadır. Denklem 4.49’da verildiği gibi girdi katmanındaki değerler ağırlıklar ile çarpılır ve bias eklenerek doğrusal olmayan bir fonksiyona girdi olmaktadır. Bu fonksiyonun sonucu gizli katmandaki nöronun değerini vermektedir (Noriega, 2005).

$$h_j = f\left(\sum_i w_{ij} x_i + b_j^1\right) \quad (4.49)$$

Denklemde x_i girdi parametrelerini, w_{ij} i. girişi j. gizli nörona bağlayan ağırlık değeridir. h_j j. gizli nöronun çıktısıdır. b_j^1 bias ve f de aktivasyon fonksiyonudur. Aktivasyon fonksiyonu olarak doğrusal (pureline), tanjant hiperbolik, lojistik sigmoid ve radyal temelli aktivasyon fonksiyonları kullanılmakla birlikte lojistik sigmoid en sık kullanılan ve bu tez çalışmasında da tercih edilen aktivasyon fonksiyonudur. Fonksiyona ait matematiksel ifadesi Denklem 4.50’de verildiği gibidir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.50)$$

Gizli katmanda elde edilen değerın çıktı katmanı aktarırken de aktivasyon fonksiyonlarından yararlanılır. Sınıflandırma problemlerinde genellikle softmax fonksiyonu tercih edilmektedir. Çıktı katmanındaki her sınıf için bir olasılık değeri üretilir ve bu değerlerin toplamı 1’e eşittir. Olasılık değerinin en yüksek olduğu sınıf tahmin etiketi olarak belirlenmektedir (Noriega, 2005). Çıktı katmanında yer alan y_j çıktısına ait matematiksel ifade Denklem 4.51 ve 4.52’de yer aldığı gibidir.

$$y_j = softmax(z_j) = \frac{e^{z_j}}{\sum_j e^{z_j}} \quad (4.51)$$

$$z_j = \sum_i w'_{ij} h_i + b_j^2 \quad (4.52)$$

Burada, z_j çıkış birimlerini, b_j^2 biası ve w'_{ij} , j’inci çıkış nöronu ile i’inci gizli nöron arasındaki ağırlık değerini temsil etmektedir.

Bir ANN’nin optimizasyon veya öğrenme olarak da bilinen eğitim süreci, tahmin edilen çıktı ile gerçek çıktı arasındaki farkı en aza indirmek için ağırlık parametrelerinin yinelemeli olarak ayarlanmasını içermektedir. Süreç, ağırlık


ağırlıklarının ve biaslarının rastgele değerler atanarak başlaması ve ardından bir çıktı üretmek için girdi verilerinin ağ üzerinden ileriye doğru yayılmasıyla devam eder. Çıktı, gerçek çıktı ile karşılaştırılır ve ikisi arasındaki fark bir kayıp fonksiyonu kullanılarak hesaplanır. Geriye doğru yayılma daha sonra ağırlıklarına ve biaslarına göre kayıp fonksiyonunun gradyanını hesaplamak için kullanılmaktadır. Bu gradyan, gradyan inişi adı verilen bir süreçte ağırlıkların ve biasların güncellemek için kullanılır. Ağırlıklar ve biaslar, kayıp fonksiyonu kabul edilebilir bir seviyeye indirilene veya bir durdurma kriteri karşılanana kadar sürekli güncellenmektedir. Süreç boyunca ağ, verilerdeki örüntüleri kademeli olarak öğrenmekte ve daha doğru tahminler yapmak için parametrelerini ayarlamaktadır. Eğitim süreci zaman alıcı olabilmekte ve ağırlıkların verilerle aşırı veya yetersiz uyumu söz konusu olabilmektedir. Eğitim işleminde katmanlar arasındaki ağırlık ve bias değerlerinin belirlenmesi için Levenberg-Marquardt (LM), Bayesian düzenleme (Bayesian Regularization, BR) ve Ölçeklendirilmiş Konjuge Gradyan (Scaled Conjugate Gradient, SCG) gibi çok sayıda optimizasyon algoritmaları kullanılmaktadır. Bu tez çalışmasında diğer algoritmalarla kıyasla hızlı olması, ağırlık ezberleme sorununu azaltmada başarılı olması ve sınıflandırma problemlerinde sıklıkla kullanılması nedeniyle SCG algoritması tercih edilmiştir. SCG algoritması, ağırlık hata fonksiyonunu minimize etmek için kullanılan bir optimizasyon algoritmasıdır. Ağırlık parametrelerini güncellemek için geriye doğru yayılım yöntemini kullanır. Diğer optimizasyon algoritmalarından farklı olarak, ağırlık parametrelerinin güncellenmesi için bir doğrusal arama yapmaktadır. Bu doğrusal arama, ağırlık hata fonksiyonunu en aza indiren ve ağırlık parametrelerinin güncellenmesi için kullanılan en iyi adım boyutunu hesaplamaktadır (Hopfield, 1988; Möller, 1993).

4.6. Performans Değerlendirme

Sınıflandırma işleminden elde edilen sonuçların doğruluğunu ve etkinliğini değerlendirmek, modelin performansını anlamak için oldukça önemlidir. Bu tez çalışmasında performansın objektif bir şekilde ölçülmesi için k-katlı çapraz doğrulama tekniği, karışıklık matrisi temelli metrikler ve ROC eğrileri kullanılmıştır.

Çapraz doğrulama yöntemi; performans ölçümü, aşırı uyum problemi önlemek ve hiperparametrelerin ayarlanması amacıyla makine öğrenmesinde sıklıkla kullanılan bir tekniktir. Bu teknik veri setini eşit boyutlarda k parçaya ayırarak, her seferinde bir parçayı test seti olarak kullanıp geri kalan k-1 parçayı eğitim seti olarak kullanarak k

defa işlem yapmaktadır. Bu işlem sonucunda, her parça test seti olarak kullanılarak modelin performansı k kere ölçülür ve sonuçlar ortalaması alınarak, modelin gerçek performansı tahmin edilir. Şekil 4.19'da çapraz doğrulamaya örnek görsel yer almaktadır. K değeri genel olarak 5 veya 10 olarak seçilmekle birlikte veri setinin boyutuna ve kullanılan modelin karmaşıklığına göre de farklı sayılar seçilebilmektedir.



Şekil 4.19. K-katlı çapraz doğrulama gösterimi

K-katlı çapraz doğrulama işlemindeki test bloklarının değerlendirilmesi için Tablo 4.4'te yer alan KAH ve Kontrol olmak üzere iki sınıflı karışıklık matrisi tablosu kullanılmaktadır (Luque vd., 2019).

Tablo 4.4. İki sınıflı bir karışıklık matrisi

Gerçek Sınıf	Tahmin Sınıf	
	1: Pozitif (KAH)	0: Negatif (Kontrol)
1: Pozitif (KAH)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
0: Negatif (Kontrol)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Tablodaki DP; KAH grubunda olan kişilerin KAH olarak sınıflandırılması, YN; KAH grubunda olan kişilerin Kontrol olarak sınıflandırılması, YP; Kontrol grubunda olan kişilerin KAH olarak sınıflandırılması ve DN; Kontrol grubunda olan kişilerin

Kontrol olarak sınıflandırılması anlamlarına gelmektedir. Karışıklık matrisi yardımı ile sınıflandırma performansını belirlemek için kullanılan metrikler tanımlamaları ve matematiksel ifadeleri ile aşağıdaki gibidir (Chicco vd., 2021; Room, 2019).

Doğruluk (Accuracy, ACC): Doğru tahmin edilen değerlerin toplam değerlere oranıdır. Doğruluk değeri 0 ile 1 arasında bir değer verir, 1 değeri hatanın olmadığına işaret eder. Bu metrik aşağıdaki diğer metrikler ile birlikte kullanılmalıdır. Dengesiz verilerde doğruluk tek başına yanıltıcı olabilmektedir.

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \quad (4.53)$$

Duyarlılık (Sensitivity veya Recall, SNS): Hassasiyet, bir modelin gerçekte pozitif olan tüm örnekler arasında pozitif örnekleri ne kadar doğru tanımladığını ölçer. Yüksek bir duyarlılık değeri, modelin yüksek oranda pozitif örneği doğru tahmin ettiğini gösterirken, düşük duyarlılık değeri modelin bazı pozitif örnekleri yanlışlıkla negatif olarak sınıflandırdığını gösterir. Duyarlılık genellikle bir sınıflandırma modelinin genel performansını değerlendirmek için özgüllük ile birlikte kullanılır.

$$SNS = \frac{TP}{TP + FN} \quad (4.54)$$

Özgüllük (Specificity, SPC): Özgüllük, bir modelin negatif olarak tahmin ettiği tüm örnekler arasında negatif örnekleri ne kadar doğru tanımladığını ölçer. Yüksek SPC değeri modelin negatif örneklerin yüksek bir oranını doğru tahmin ettiğini gösterirken, düşük özgüllük değeri modelin bazı pozitif örnekleri yanlışlıkla negatif olarak sınıflandırdığını gösterir.

$$SPC = \frac{TN}{FP + TN} \quad (4.55)$$


Kesinlik (Precision, PRC): Bir modelin pozitif olarak tahmin ettiği tüm örnekler arasında pozitif örnekleri ne kadar doğru tanımladığını ölçer. Yüksek PRC değeri, modelin yüksek oranda pozitif örneği doğru tahmin ettiğini gösterirken, düşük kesinlik değeri modelin bazı negatif örnekleri yanlış bir şekilde pozitif olarak sınıflandırdığını gösterir. Kesinlik genellikle bir sınıflandırma modelinin genel performansını değerlendirmek için duyarlılık ile birlikte kullanılır.

$$PRC = \frac{TP}{TP + FP} \quad (4.56)$$

F₁ ölçütü (F₁ score, F₁): F₁ puanı, hem yanlış pozitifleri hem de yanlış negatifleri dikkate alan bir modelin performansının tek bir ölçüsünü sağlayarak hem hassasiyeti hem de duyarlılığı dengeler. Yüksek F₁ değeri, modelin hem yüksek hassasiyete hem de yüksek duyarlılığa sahip olduğunu, yani hem pozitif hem de negatif örneklerin yüksek bir oranını doğru bir şekilde tanımladığını gösterir. Düşük F₁ değeri, modelin hem pozitif hem de negatif örnekleri doğru bir şekilde sınıflandırmakta zorlandığını gösterir.

$$F_1 = 2 \times \frac{PRC \times SNS}{PRC + SNS} \quad (4.57)$$


Bu metriklerden farklı olarak Alıcı İşletim Karakteristiği (Receiver Operating Characteristic, ROC) eğrisi de performans ölçmek için kullanılan metriklerdendir. Sınıflandırıcının tüm olası değerler üzerinde performansını özetlemek için kullanılan bir grafikdir. Şekil 4.20’de örnek ROC eğrileri yer almaktadır. Eğride x ekseninde Yanlış Pozitif Oranı (False Positive Rate, FPR) ve y ekseninde ise Doğru Pozitif Oranı (True Positive Rate, TPR) bulunmaktadır. Eğri Altındaki Alan (Area Under Curve, AUC) ise ROC eğrisinin altında kalan alandır. AUC değeri 0 ile 1 arasında bir değer almaktadır ve değer 1’e ne kadar yakınsa model performansı o kadar başarılı demektir (Hasan vd., 2020). Şekildeki A modelinin AUC değeri B modelinin AUC değerinden büyük olduğu için A modelinin B’ye göre daha başarılı olduğu ifade edilebilir.




Şekil 4.20. İki farklı modele ait örnek ROC eğrileri

4.7. Önerilen Yöntem

Tez çalışması kapsamında KAH'ın iristen tahmin edilebilmesi için görüntü işleme teknikleri, iridoloji ve makine öğrenmesi yöntemleri kullanılmıştır. Giresun Üniversitesi Eğitim ve Araştırma Hastanesi Kardiyoloji Polikliniği'nden elde edilen göz görüntüleri görüntü işleme teknikleri ile analiz edilmiş ve görüntü içerisinden Daugman'ın IDO yöntemi ile iris iç ve dış sınırları bulunmuştur. Daugman'ın Rubber Sheet tekniği ile de iris dikdörtgen bir formata dönüştürülerek sabit boyutta bir standartlaşma sağlanmıştır. İridoloji haritalarına göre kalbin iristeki konumuna göre analiz bölgesi tespit edilip o bölge öznelik çıkarma amacıyla bölütlenmiştir. Öznelik çıkarma işlemi öncesinde ise CLAHE yöntemi ile adaptif histogram eşitleme uygulanarak görüntü iyileştirme aşaması gerçekleştirilmiştir. Bu aşamaya kadar olan kısım görüntü ön-işleme aşamasıdır. Önerilen KAH tahmini süreci Şekil 4.21'deki akış şemasında verildiği gibidir. Çalışmada iris ve fizyolojik öznelikler olmak üzere iki farklı öznelik grubu yer almaktadır. Fizyolojik öznelikler gönüllülere sorularak, iris öznelikleri ise görüntü iyileştirme aşamasından sonra Şekil 4.22'deki süreç sonucunda elde edilmektedir.



Şekil 4.21. Önerilen KAH tahmini süreci



Şekil 4.22. İris özelliklerinin çıkarılma sürecine ait akış süreci

Adaptif histogram eşitleme yapılan ROI görüntüsü ilk olarak dalgacık dönüşümü kullanılarak dört alt görüntü halinde ifade edilmiştir. Bu görüntüler, LL, LH, HL ve HH isimli farklı frekans bileşenlerini içeren görüntülerdir. Ardından LL altbandına ait cA bileşenine tekrardan dalgacık dönüşümü uygulanarak 2. Seviye dönüşüm gerçekleştirilmiştir. Bu dönüşüm sonucunda da LL, LH, HL ve HH isimli alt bantlar oluşmaktadır. Bu görüntülerden beş adet birinci dereceden istatistiksel öznitelikler ile 22 adet GLCM ve 7 adet GLRLM matrislerine ait ikinci dereceden oluşan öznitelikler hesaplanmıştır. Her bölge için 34 öznitelik olmak üzere toplamda sekiz bölge (LL^1 , LH^1 , HL^1 , HH^1 , LL^2 , LH^2 , HL^2 ve HH^2) için 272 öznitelik elde edilmiştir.

Bu tez çalışması kapsamında 3. ve 4. seviye DWT dönüşümleri denenmiş ve 2 seviyeli DWT sonuçlarına kıyasla performansta bir iyileşme görülmemiştir. Artan hesaplama karmaşıklığı ile beklenen performans kazancı arasındaki denge gözetildiğinde çalışmadaki veri grubu için 2 seviye dönüşüm yeterli ve en iyi performansın elde edildiği dönüşümdür. Ek dönüşüm seviyeleri daha ince ayrıntılar sunarken, performansta orantılı artışlar sağlamadan analiz sürelerini de uzatmıştır. Sonuç olarak 2 seviyeli DWT hesaplama verimliliği ve özellik zenginliği arasında daha uygun bir dengeye ulaşmakta ve böylece özellik çıkarma ve analiz için tercih edilen seçenek olarak kendini kanıtlamıştır.

Sınıflandırma aşaması öncesinde ReliefF öznitelik seçme yöntemine göre en iyi iris öznitelikleri seçilmiştir. Çalışmada sadece iris öznitelikleri kullanılarak sınıflandırma yapıldığı gibi en iyi iris parametrelerine ilave olarak gönüllülerin biyodemografik verilerinin eklenmesi sonucunda performansa etkisi de incelenmiştir. Sınıflandırma işlemi için DT, NB, SVM, k-NN ve ANN olmak üzere beş farklı sınıflandırıcı ailesinden toplamda 22 farklı sınıflandırıcı kullanılmıştır. Bu sınıflandırıcılara ait parametreler Tablo 4.5'te verildiği gibidir.

Sınıflandırma aşamasında geniş bir perspektife ve çeşitli model parametrelerine sahip 22 model kullanılmıştır. Tablodaki modellerin çeşitliliği, farklı algoritmaların ve parametrelerin kullanılmasıyla sağlanmıştır. Bu çeşitlilik, sınıflandırma probleminin farklı yönlerini kapsayabilme ve farklı veri setlerine uyum sağlayabilme potansiyelin olduğunu göstermektedir. Öncelikle, DT temelli modeller (DT Model I, DT Model II ve DT Model III) farklı maksimum bölünme sayıları ve Gini'nin çeşitlilik endeksi gibi farklı parametrelerle sunulmuştur. Bu, ağaçların derinliği ve karmaşıklığı kontrol etmek için yeterlidir. NB modelleri (NB Model I ve NB Model II) farklı dağılım tahminleriyle birlikte gelmektedir. Gauss Dağılımı ve Kernel Dağılımı ile veri setinin istatistiksel özelliklerine farklı bir bakış açısı sunulmaktadır. SVM ise çeşitli çekirdek fonksiyonları (doğrusal, kuadratik, kübik, Gauss) ve çekirdek ölçekleri ile sunulmuştur. Bu modeller, sınıflandırma problemlerine geniş bir perspektif sunmaktadır. k-NN modelleri farklı komşu sayıları, uzaklık metrikleri (Öklid, Kosinüs, Minkowski) ve mesafe ağırlıkları ile sunulmuştur. Son olarak, ANN modelleri, farklı tam bağlı katman sayıları, katman boyutları ve aktivasyon fonksiyonları ile kullanılmıştır. Bu geniş ve çeşitli model seçenekleri, sınıflandırma problemine geniş kapsamlı bir yaklaşım sağlayarak, farklı veri setleri ve senaryolar için uygun seçenekler sunmaktadır.

Tablo 4.5. Çalışmada kullanılan sınıflandırıcı model isimleri ve parametreleri

Sıra	Model	Model Parametreleri	Sıra	Model	Model Parametreleri
1	DT Model I	Maksimum bölünme sayısı: 100 Bölünme kriteri: Gini'nin çeşitlilik endeksi	12	k-NN Model I	Komşu sayısı: 1 Uzaklık metriği: Öklid
2	DT Model II	Maksimum bölünme sayısı: 20 Bölünme kriteri: Gini'nin çeşitlilik endeksi	13	k-NN Model II	Komşu sayısı: 10 Uzaklık metriği: Öklid
3	DT Model III	Maksimum bölünme sayısı: 4 Bölünme kriteri: Gini'nin çeşitlilik endeksi	14	k-NN Model III	Komşu sayısı: 100 Uzaklık metriği: Öklid Mesafe ağırlığı: Eşit
4	NB Model I	Gauss Dağılımı	15	k-NN Model IV	Komşu sayısı: 10 Mesafe metriği: Kosinüs Mesafe ağırlığı: Eşit
5	NB Model II	Kernel Dağılımı	16	k-NN Model V	Komşu sayısı: 10 Uzaklık metriği: Minkowski Mesafe ağırlığı: Eşit
6	SVM Model I	Çekirdek fonksiyonu: Doğrusal	17	k-NN Model VI	Komşu sayısı: 10 Uzaklık metriği: Öklid Mesafe ağırlığı: Kareli ters
7	SVM Model II	Çekirdek fonksiyonu: Kuatratik	18	ANN Model I	Tam bağlı katman sayısı: 1 İlk katman boyutu: 10 Aktivasyon: ReLU
8	SVM Model III	Çekirdek fonksiyonu: Kübik	19	ANN Model II	Tam bağlı katman sayısı: 1 İlk katman boyutu: 25 Aktivasyon: ReLU
9	SVM Model IV	Çekirdek fonksiyonu: Gauss Çekirdek ölçeği: 4.1	20	ANN Model III	Tam bağlı katman sayısı: 1 İlk katman boyutu: 100 Aktivasyon: ReLU
10	SVM Model V	Çekirdek fonksiyonu: Gauss Çekirdek ölçeği: 16	21	ANN Model IV	Tam bağlı katman sayısı: 2 İlk katman boyutu: 10 İkinci katman boyutu: 10 Aktivasyon: ReLU
11	SVM Model VI	Çekirdek fonksiyonu: Gauss Çekirdek ölçeği: 66	22	ANN Model V	Tam bağlı katman sayısı: 3 İlk katman boyutu: 10 İkinci katman boyutu: 10 Üçüncü katman boyutu: 10 Aktivasyon: ReLU

Sınıflandırma işleminde 10-katlı çapraz doğrulama uygulanarak test verilerine ait Performans Değerlendirmesi isimli başlık altında yer alan metriklerin ortalama değerleri hesaplanmıştır.

5. BULGULAR VE TARTIŞMA

Bu tez çalışmasında, KAH'ın tahmin edilmesi için 281 gönüllüye ait iris görüntüleri kullanılmıştır. Görüntü işleme teknikleri ve iridolojinin harmanlanmasıyla önerilen yöntemde dalgacık dönüşümü temelli öznitelik çıkarma işlemi uygulanmıştır. Elde edilen iris öznitelikleri ReliefF öznitelik seçme algoritması ile belirlenen iyi özniteliklere göre sınıflandırma sürecine aktarılmıştır. NB, DT, k-NN, SVM ve ANN olmak üzere beş farklı sınıflandırıcı ailesi kullanılarak sınıflandırma aşaması gerçekleştirilmiştir. 10 katlı çapraz doğrulama ile test verilerine ait performans değerlendirmeleri doğruluk, duyarlılık, özgüllük, kesinlik, F_1 ölçütü ve AUC metriklerine göre yapılmıştır. Ayrıca iris özniteliklerine ek olarak fizyolojik parametreler de analize dahil edilerek aynı en iyi sonuçların elde edildiği sınıflandırıcılarda analiz tekrarlanmıştır. Bu çalışmada yapılan tüm analizler MATLAB programlama dili kullanılarak gerçekleştirilmiştir.


Bu başlık altında öncelikle toplanmış olan verilere ait istatistiksel bilgilere yer verilecektir. Sonrasında ise özniteliklere ait korelasyon katsayıları ve her bir sınıflandırıcı özelindeki bulgular verilerek tartışma ile bölüm sonlandırılacaktır.

5.1. Verilere Ait İstatistiksel Bilgiler


Bu çalışmanın veri seti, gönüllülerin onayı ve Giresun Üniversitesi Sağlık Uygulama ve Araştırma Hastanesi Kardiyoloji Polikliniği'nden ilgili doktorların yardımıyla 281 denekten iris görüntüleri toplanarak oluşturulmuştur. Veri toplama işlemi için Samsun Üniversitesi Klinik Araştırmalar Etik Kurulu'nun 23.11.2022 tarih ve SUKAEK-2022 12/21 sayılı kararı ile etik kurul onayı alınmıştır. 281 gönüllüden 156'sı KAH tanısı almış, 126'sı ise hastalığı olmayan sağlıklı bireylerden oluşmuştur. KAH'ın görülme sıklığı cinsiyete göre değişmekte olup, erkeklerde daha yaygındır (Virani vd., 2020). Sonuç olarak, çalışmaya dahil edilen gönüllüler arasında erkeklerin oranı kadınlardan daha yüksektir. Çalışmaya katılan ve yaşları 19 ile 86 arasında değişen gönüllülerin 225'i erkek, 56'sı ise kadındır. Tablo 5.1, Şekil 5.1 ve Şekil 5.2'de gönüllülerin yaş, cinsiyet ve sağlık durumları hakkında ayrıntılı bilgi vermektedir.

Tablo 5.1. Gönüllülere ait yaş ve cinsiyete göre istatistiksel bilgiler

Sınıf	Erkek	Kadın	Ortalama Yaş	Standart Sapma	Toplam Sayı
Kontrol	97	29	55.41	13.6	126
KAH	128	27	59.88	9.6	155



Şekil 5.1. Gönüllülerin yaşlarına göre sağlık durumu bilgileri




Şekil 5.2. Gönüllülerin yaşlarına göre cinsiyet bilgileri


5.2. Öznitelik Analizi

5.2.1. İris Öznitelikleri

Dalgacık dönüşümünden elde edilen 272 özelliğin hedef değişken ile ilişkisini gösteren korelasyon katsayısı değerleri Şekil 5.3 ve Şekil 5.4'te gösterilmiştir. Şekil 5.3'te 1 seviye Dalgacık dönüşümü sonucunda elde edilen parametrelere ait korelasyon katsayıları yer alırken, Şekil 5.4'te cA bileşeni kullanılarak 2 seviye Dalgacık dönüşümü sonucunda elde edilen özniteliklerin korelasyon katsayıları yer almaktadır. Çalışmada; Şekil 5.4'teki 136 öznitelik, Şekil 5.3'teki 136 özneliğin devamı niteliğinde olmak üzere toplamda 272 öznitelik kullanılmıştır. Dalgacık dönüşümü sonrasında sekiz bileşene ayrılan analiz bölgesindeki her bir bileşen için sırasıyla 5 istatistiksel, 22 GLCM ve 7 GLRLM özelliği olmak üzere 34 öznitelik çıkarılmıştır. Sekiz bileşen de sırasıyla cA^1 , cH^1 , cV^1 , cD^1 , cA^2 , cH^2 , cV^2 ve cD^2 dir.



Şekil 5.3. 1 seviye DWT dönüşümü sonucunda elde edilen öznitelikler ve korelasyon katsayıları



Şekil 5.4. 2 seviye DWT dönüşümü sonucunda elde edilen öznitelikler ve korelasyon katsayıları

En yüksek korelasyon değeri olan 0.7043, 127. öznitelik olan cA^1 alt bandının GLCM özniteliği olan Toplam Varyans'a aittir. Bu öznitelik 0.7 üzerinde korelasyon katsayısına ait tek özniteliktir. Korelasyon değeri 0.6-0.7 arasında toplamda 28 öznitelik, 0.5-0.6 arasında değerlere sahip 2 öznitelik, 0.4-0.5 arasında 4 öznitelik, 0.3-0.4 arasında 30 öznitelik ve 0.2-0.3 arasında 97 öznitelik bulunmaktadır. En yüksek korelasyon katsayısına sahip 10 öznitelik arasında cA^1 bileşeninde 4, cD^1 bileşeninde 2, cA^2 bileşeninde 2 ve cD^2 bileşeninde 2 öznitelik bulunmaktadır. Bu özniteliklerin hepsi de GLCM özniteliklerine aittir. Tüm parametreler incelendiğinde GLCM matrisine ait parametrelerin en yüksek korelasyon katsayısına sahip olduğu görülmektedir. GLRLM'ye ait özniteliklerin de yüksek korelasyon katsayılarına sahip olduğu ifade edilmekle birlikte birlikte birinci dereceden istatistiksel parametreler diğer gruplara göre düşük kalmıştır. Özniteliklerin korelasyon katsayılarına bakılarak, dalgacık dönüşümünden elde edilen bileşenler arasında eşit olarak dağıldığı görülebilir. İstatistiksel özelliklerin diğer özellik gruplarına kıyasla daha düşük korelasyon katsayılarına sahip olduğu ve en yüksek katsayıların sırasıyla GLRLM ve GLCM özelliklerinde olduğu söylenebilir.

Sınıflandırma işleminden önce öznitelik seçme işlemi uygulanmıştır. ReliefF algoritması kullanılarak rank değerlerine göre en iyi 25, 50, 75, 100, 125, 150, 175, 200, 225, 250 ve 272 özellik belirlenmiştir. En yüksek sıralamaya sahip ilk 25 (Grup 1), ikinci 25 (Grup 2), üçüncü 25 (Grup 3), dördüncü 25 (Grup 4), beşinci 25 (Grup 5), altıncı 25 (Grup 6), yedinci 25 (Grup 7), üçüncü 25 (Grup 8), dokuzuncu 25 (Grup 9), onuncu 25 (Grup 10) ve on birinci 25 (Grup 11) öznitelik grupları Tablo 5.2'de listelenmiştir.

Korelasyon katsayıları, özniteliklerin birbiriyle olan doğrusal ilişkilerini ölçer. Yüksek korelasyon, iki parametrenin birbiriyle güçlü bir ilişkisi olduğunu anlamına gelmektedir. ReliefF ise özniteliklerin sınıflandırma görevine olan katkısını değerlendirirerek sınıflandırma performansını artırmayı amaçlar. Bu nedenle, ReliefF ve korelasyon katsayıları, farklı açılardan özniteliklerin önemini değerlendirirler. Şekil 5.3 ve Şekil 5.4'te yer alan iris özniteliklerinin korelasyon katsayıları ile Tablo 5.2'de yer alan ReliefF öznitelik seçme yöntemi sonucunda sıralanan parametreler incelendiğinde, korelasyon katsayılarına göre yüksek bir ilişki gösteren özniteliklerin, ReliefF'e göre önem sıralamaları düşük olabilmektedir. Örnek olarak, 144 ve 262 numaralı öznitelikler, korelasyona göre yüksek bir ilişkiye sahipken, ReliefF'e göre daha düşük bir öneme sahiptir.

Tablo 5.2. ReliefF yöntemine göre en yüksek rank değerine sahip öznitelikler

Grup	Öznitelik Numarası
1	262, 263, 103, 126, 239, 127, 171, 35, 101, 205, 237, 71, 105, 67, 228, 189, 187, 229, 141, 188, 194, 176, 5, 190, 69
2	181, 195, 152, 151, 227, 225, 162, 217, 172, 148, 244, 163, 218, 159, 143, 158, 7, 22, 248, 27, 4, 164, 12, 26, 15
3	16, 257, 254, 125, 149, 256, 146, 31, 153, 147, 180, 253, 142, 258, 150, 59, 251, 23, 156, 207, 140, 157, 14, 37, 264
4	13, 106, 21, 246, 247, 155, 17, 11, 255, 208, 10, 20, 241, 250, 249, 116, 154, 265, 6, 260, 245, 183, 19, 261, 18
5	123, 113, 222, 259, 53, 193, 220, 191, 70, 219, 52, 223, 192, 177, 215, 252, 72, 85, 206, 28, 122, 184, 197, 167, 174
6	211, 226, 51, 40, 107, 104, 115, 182, 108, 54, 81, 112, 161, 224, 120, 231, 33, 121, 196, 110, 111, 203, 169, 216, 221
7	109, 124, 230, 209, 82, 129, 214, 2, 186, 90, 75, 210, 118, 178, 179, 114, 138, 95, 117, 240, 185, 87, 119, 232, 80
8	128, 41, 56, 269, 86, 94, 61, 3, 91, 242, 89, 32, 38, 93, 46, 266, 45, 83, 84, 88, 267, 145, 144, 25, 73
9	168, 24, 36, 74, 96, 47, 139, 212, 213, 135, 60, 271, 243, 99, 130, 79, 235, 55, 57, 48, 30, 34, 58, 160, 78
10	165, 202, 134, 166, 170, 29, 44, 100, 270, 50, 49, 236, 62, 131, 77, 76, 173, 9, 8, 1, 132, 136, 137, 133, 268
11	272, 198, 42, 43, 97, 200, 204, 98, 102, 92, 233, 65, 234, 238, 66, 201, 175, 64, 68, 63, 39, 199

5.2.2. Fizyolojik Öznitelikler

Tez çalışmasında 155 gönüllü KAH grubunu, 126 gönüllü Kontrol grubunu oluşturmaktadır. Gruplara ait özniteliklerin ortalama ve standart sapmaları ile korelasyon katsayılarını gösteren detaylı istatistiksel ifadeler Tablo 5.3’te verilmektedir. En yüksek korelasyon katsayısı 0.4167 ile “Sigara kullanma” durumunda çıkarken 0.3918 ile “kolesterol” ikinci sırada ve 0.3178 ile “aile öyküsü” de en yüksek üçüncü parametre durumundadır.

Tablo 5.3. Fizyolojik parametrelere ait istatistiksel bilgiler ve korelasyon katsayıları (n=281)

Öznitelik İsmi	KAH (n=155)	Kontrol (n=126)	Korelasyon katsayısı
	Ort±Ss	Ort±Ss	
Cinsiyet	0.79±0.41	0.77±0.42	0.0697
Yaş (yıl)	59.88±9.6	55.41±13.6	0.1891
Boy (cm)	167.87±7.69	166.41±8.87	0.0952
Kilo (kg)	81.36±12.44	76.95±12.11	0.1562
VKİ (kg/m ²)	28.89±4.09	27.90±4.74	0.0846
VKİ	0.49±0.50	0.25±0.43	0.2255
Aile Öyküsü	0.75±0.44	0.44±0.50	0.3178
Sigara Kullanma	0.52±0.50	0.25±0.44	0.4167
Alkol Kullanma	0.37±0.49	0.10±0.31	0.3093
Egzersiz	0.16±0.37	0.53±0.50	0.1831
Kolesterol	0.62±0.49	0.21±0.41	0.3918
Diyabet	0.44±0.50	0.19±0.39	0.2740
Stres	0.66±0.48	0.48±0.50	0.1754
Tansiyon	0.76±0.43	0.38±0.49	0.3480

KAH: Koroner Arter Hastalığı; Ort: Ortalama; Ss: Standart sapma; VKİ: Vücut Kitle İndeksi

Gönüllülere ait bu fizyolojik parametreler iris öznitelikleri ile gerçekleştirilen sınıflandırma işlemi sonucunda en iyi performansa sahip sınıflandırıcılarının belirlenmesinin ardından iris öznitelikleri ile birleştirilerek performans analizlerine dahil edilmiştir.

5.3. Naive Bayes Sınıflandırıcısına Ait Bulgular

Çalışmada, NB sınıflandırıcısına ait iki model kullanılmıştır. Tablo 5.4 ve Tablo 5.5'te bu modellere ait performans değerleri yer almaktadır. Tablo 5.4'te Normal dağılıma sahip NB sınıflandırıcısının farklı öznitelik sayılarına göre performans metriklerine ait değerler yer almaktadır. Tabloya göre en yüksek doğruluk %89.29 ile 25 öznitelik kullanıldığında elde edilmiştir. Aynı öznitelik sayısında duyarlılık %95.56 ile ve F₁ ölçütü %90.53 ile en yüksek değerindedir. Özgüllük ve kesinlik değerleri de

%92.31 ve %86.96 ile 100 öznitelik olduğu analizde en yüksek değerdedir. Öznitelik sayısının 50 olduğu durumda %84.52'lik bir doğruluk elde edilmekle birlikte 75 öznitelik ve üzerinde doğruluk değeri nispeten düşüş göstermektedir.

Tablo 5.4. NB Model I bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8929	0.9556	0.8205	0.8600	0.9053
50	0.8452	0.8444	0.8462	0.8636	0.8539
75	0.7262	0.5778	0.8974	0.8667	0.6933
100	0.6667	0.4444	0.9231	0.8696	0.5882
125	0.6190	0.4444	0.8205	0.7407	0.5556
150	0.6190	0.4444	0.8205	0.7407	0.5556
175	0.6190	0.4667	0.7949	0.7241	0.5676
200	0.6429	0.5111	0.7949	0.7419	0.6053
225	0.6786	0.5556	0.8205	0.7812	0.6494
250	0.7262	0.6444	0.8205	0.8056	0.7160
272	0.7500	0.6667	0.8462	0.8333	0.7407


Tablo 5.5'te Kernel dağılıma sahip NB sınıflandırıcısına ait farklı öznitelik sayılarına göre performans metriklerine ait değerler yer almaktadır. Doğruluk oranı gözlemlenen öznitelik sayısına bağlı olarak değişkenlik göstermektedir. 25 öznitelik kullanıldığında yüksek bir doğruluk oranı (%86.90) elde edilmiştir. Ancak, öznitelik sayısı arttıkça doğruluk oranı genellikle düşmektedir. Bu durum, modelin doğru sınıflandırma yapma yeteneğinin öznitelik sayısına bağlı olarak azaldığını göstermektedir. Duyarlılık değeri, öznitelik sayısının artmasıyla birlikte artmaktadır. Bu, modelin KAH sınıfına ait örnekler doğru bir şekilde tespit etme yeteneğinin öznitelik sayısı ile birlikte arttığını göstermektedir. Ancak, 100 öznitelikten sonra duyarlılık oranındaki artış sınırlıdır. Özgüllük değeri ise genellikle düşük değerlere sahiptir. Bu durum, modelin Kontrol grubuna ait örnekleri yanlış bir şekilde KAH olarak sınıflandırma eğiliminde olduğunu göstermektedir. Öznitelik sayısının artmasıyla birlikte özgüllük oranı düşmektedir. Kesinlik, öznitelik sayısına bağlı olarak değişkenlik göstermektedir. 250 öznitelik kullanıldığında en yüksek kesinlik oranı (%71.70) elde edilirken, 75 öznitelikte bu oran daha düşüktür (%60.00). Bu, modelin doğru pozitif sınıflandırmaları yapma yeteneğinin öznitelik sayısı ile birlikte

arttığını göstermektedir. 272 öznitelik kullanıldığında en yüksek F1 ölçütü (%80.00) elde edilirken, 125 öznitelikte bu oran daha düşüktür (%69.09).

Tablo 5.5. NB Model II bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8690	0.9111	0.8205	0.8542	0.8817
50	0.7024	0.8667	0.5128	0.6724	0.7573
75	0.6190	0.8667	0.3333	0.6000	0.7091
100	0.6071	0.8667	0.3077	0.5909	0.7027
125	0.5952	0.8444	0.3077	0.5846	0.6909
150	0.6071	0.8444	0.3333	0.5938	0.6972
175	0.6548	0.8444	0.4359	0.6333	0.7238
200	0.6786	0.8222	0.5128	0.6607	0.7327
225	0.7024	0.8222	0.5641	0.6852	0.7475
250	0.7381	0.8444	0.6154	0.7170	0.7755
272	0.7738	0.8444	0.6923	0.7600	0.8000

Şekil 5.5'te Normal ve Kernel dağılım NB sınıflandırıcısı için ROC eğrileri yer almaktadır. NB Model I etiketli eğri normal dağılıma sahipken, NB Model II etiketi Kernel dağılıma sahiptir. Normal dağılım NB için AUC değeri 0.9373 iken Kernel dağılım için 0.9328'dir.



Şekil 5.5. NB sınıflandırıcıları için ROC eğrileri

5.4. Karar Ağaçları Sınıflandırıcısına Ait Bulgular

Karar Ağaçları sınıflandırıcısı olarak üç farklı model kullanılmıştır. Üç modele ait analiz sonuçları Tablo 5.6, Tablo 5.7 ve Tablo 5.8’de verilmektedir. Tablo 5.6’da Fine Tree sınıflandırıcısına ait bulgular yer almaktadır. Doğruluk değeri NB sınıflandırıcısına ait bulgulara göre genellikle yüksek seviyelerde gözlemlenmektedir ve öznelilik sayısı arttıkça istikrarlı bir şekilde yüksek seviyede kalmaktadır. En yüksek gözlenen doğruluk değeri %88.1’dir. Ancak, 125 öznelikten sonra doğruluk oranında düşüş görülmektedir. Duyarlılık, 25 öznelikten başlayarak yüksek seviyelerde başlamakta ve öznelilik sayısı arttıkça sabit bir şekilde devam etmektedir. Özgüllük, kesinlik ve F_1 ölçütü değerleri de genellikle yüksek seviyelerde gözlemlenmektedir ve öznelilik sayısı arttıkça sabit bir şekilde devam etmektedir. Özgüllük, kesinlik ve F_1 ölçütüne ait en yüksek değerler sırasıyla %89.74, %90.7 ve %88.64’tür.

Tablo 5.6. DT Model I bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8333	0.8889	0.7692	0.8163	0.8511
50	0.8810	0.8667	0.8974	0.9070	0.8864
75	0.8810	0.8667	0.8974	0.9070	0.8864
100	0.8810	0.8667	0.8974	0.9070	0.8864
125	0.8452	0.8667	0.8205	0.8478	0.8571
150	0.7976	0.8000	0.7949	0.8182	0.8090
175	0.7976	0.8000	0.7949	0.8182	0.8090
200	0.7857	0.8000	0.7692	0.8000	0.8000
225	0.7857	0.8000	0.7692	0.8000	0.8000
250	0.7619	0.9333	0.5641	0.7119	0.8077
272	0.7738	0.9333	0.5897	0.7241	0.8155

Tablo 5.7’de Medium Tree sınıflandırıcısına ait bulgular yer almaktadır. Doğruluk, 50, 75 ve 100 öznitelik kullanıldığında %88.1 ile en yüksek değerlerindedir. 100 öznitelik üzerinde değer düşmekle birlikte birbirine yakın seyretmektedir. Aynı durum Özgüllük, kesinlik ve F₁ ölçütü değerleri için de geçerlidir. Bu metriklere ait değerler sırasıyla %89.74, %90.7 ve %88.64’tür. Özgüllük değerinde 250 ve üzeri öznitelik sayısında sert bir düşüş gözlemlenmekle birlikte duyarlılık metriğinde %93.33 ile en yüksek değerler elde edilmiştir.

Tablo 5.7. DT Model II bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8333	0.8889	0.7692	0.8163	0.8511
50	0.8810	0.8667	0.8974	0.9070	0.8864
75	0.8810	0.8667	0.8974	0.9070	0.8864
100	0.8810	0.8667	0.8974	0.9070	0.8864
125	0.8452	0.8667	0.8205	0.8478	0.8571
150	0.7976	0.8000	0.7949	0.8182	0.8090
175	0.7976	0.8000	0.7949	0.8182	0.8090
200	0.7857	0.8000	0.7692	0.8000	0.8000
225	0.7857	0.8000	0.7692	0.8000	0.8000
250	0.7619	0.9333	0.5641	0.7119	0.8077
272	0.7738	0.9333	0.5897	0.7241	0.8155


Tablo 5.8’de Coarse Tree sınıflandırıcısına ait bulgular yer almaktadır. Bulgular Medium Tree sınıflandırıcısına yakın değerlerdir. En yüksek doğruluk %85.71 olarak

bulunurken duyarlılık, özgüllük, kesinlik ve F_1 ölçütü için en yüksek bulunan değerler sırasıyla %93.33, %82.05, %85.11 ve %86.96'dır.

Tablo 5.8. DT Model III bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F_1 ölçütü
25	0.8333	0.9333	0.7179	0.7925	0.8571
50	0.8571	0.8889	0.8205	0.8511	0.8696
75	0.8571	0.8889	0.8205	0.8511	0.8696
100	0.8571	0.8889	0.8205	0.8511	0.8696
125	0.8571	0.8889	0.8205	0.8511	0.8696
150	0.8333	0.8667	0.7949	0.8298	0.8478
175	0.8333	0.8667	0.7949	0.8298	0.8478
200	0.8333	0.8667	0.7949	0.8298	0.8478
225	0.8333	0.8667	0.7949	0.8298	0.8478
250	0.7976	0.9333	0.6410	0.7500	0.8317
272	0.8095	0.9333	0.6667	0.7636	0.8400

Şekil 5.6'da Karar Ağaçları sınıflandırıcılarına ait ROC eğrileri yer almaktadır. Model 1 ve Model 2 için aynı eğri ve AUC değeri elde edilmiştir. Fine Tree (Model I), Medium Tree (Model II) ve Coarse Tree (Model III) modellerine ait AUC değerleri sırasıyla 0.8721, 0.8721 ve 0.8801'dir.



Şekil 5.6. DT sınıflandırıcıları için ROC eğrileri

5.5. k-NN Sınıflandırıcısına Ait Bulgular

Çalışmada knn sınıflandırıcısı kullanılarak altı farklı model oluşturulmuş ve analiz işlemi yapılmıştır. k-NN sınıflandırıcısına ait bulgular Tablo 5.9, Tablo 5.10, Tablo 5.11, Tablo 5.12, Tablo 5.13 ve Tablo 5.14'te yer almaktadır. Tablo 5.9'da Fine k-NN modeline ait sonuçlar verilmektedir. Genel olarak, öznitelik sayısı arttıkça doğruluk, duyarlılık, özgüllük ve F_1 ölçütü yükselirken, kesinlik değeri dalgalanmaktadır. Ancak, 200'den sonra öznitelik sayısı arttıkça performans önemli ölçüde düşmektedir. En iyi performansı sağlayan öznitelik sayısının 75 olduğunu söylenebilir. Bu durumda, doğruluk, kesinlik ve F_1 ölçütü %85.71, %82.35 ve %87.5 ile en yüksek değerlere sahiptir. Duyarlılık ve özgüllük değerleri de %93.33 ve %76.92 ile kabul edilebilir düzeydedir.

Tablo 5.9. k-NN Model I bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.7262	0.8667	0.5641	0.6964	0.7723
50	0.7976	0.9333	0.6410	0.7500	0.8317
75	0.8571	0.9333	0.7692	0.8235	0.8750
100	0.8452	0.9556	0.7179	0.7963	0.8687
125	0.8095	0.9333	0.6667	0.7636	0.8400
150	0.7500	0.8667	0.6154	0.7222	0.7879
175	0.7500	0.8222	0.6667	0.7400	0.7789
200	0.5238	0.9333	0.5130	0.5316	0.6774
225	0.5357	0.9333	0.7692	0.5385	0.6829
250	0.5119	0.9111	0.5130	0.5256	0.6667
272	0.5000	0.8889	0.5130	0.5195	0.6557

Tablo 5.10’da Medium k-NN modeline ait sonuçlar verilmektedir. Öznitelik sayısı arttıkça genel olarak doğruluk ve F₁ ölçütü artmaktadır. Ancak, 200’den sonra öznitelik sayısı arttıkça performansın önemli ölçüde düştüğü söylenebilir. Duyarlılık değeri ise 1’e yaklaşmış ve sabit kalmış gibi görünmektedir. Yani öznitelik sayısının artması duyarlılığı etkilememektedir. Özgüllük değeri 0.6667 olarak sabit kalmıştır. Kesinlik değeri ise öznitelik sayısının artmasıyla dalgalanmaktadır. Bu bilgilere dayanarak, en iyi performansı sağlayan öznitelik sayısının 50 olduğu ifade edilebilir. Bu durumda, doğruluk, duyarlılık, özgüllük, kesinlik ve F₁ ölçütü sırasıyla %84.52, %100, %66.67, %77.59 ve %87.38 ile en yüksek değerlere sahiptir.

Tablo 5.10. k-NN Model II bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8333	0.9778	0.6667	0.7719	0.8627
50	0.8452	1.0000	0.6667	0.7759	0.8738
75	0.8452	1.0000	0.6667	0.7759	0.8738
100	0.8095	1.0000	0.5897	0.7377	0.8491
125	0.8214	0.9778	0.6410	0.7586	0.8544
150	0.8452	1.0000	0.6667	0.7759	0.8738
175	0.8333	0.9778	0.6667	0.7719	0.8627
200	0.5357	1.0000	0.0000	0.5357	0.6977
225	0.5357	1.0000	0.0000	0.5357	0.6977
250	0.5357	1.0000	0.0000	0.5357	0.6977
272	0.5357	1.0000	0.0000	0.5357	0.6977

Tablo 5.11’de Coarse k-NN modeline ait sonuçlar verilmektedir. Öznitelik sayısı arttıkça doğruluk, duyarlılık, özgüllük ve F1 ölçütü değerleri genellikle artış göstermektedir. Ancak, 200’den sonra öznitelik sayısının artması performansı önemli ölçüde düşürmektedir. Özgüllük değerinin 0.5385 olarak sabit kaldığı söylenebilir. Kesinlik değeri öznitelik sayısının artmasıyla dalgalanmaktadır. Bu bilgilere dayanarak, en iyi performansı sağlayan öznitelik sayısının 75 olduğu söylenebilir. Bu durumda, doğruluk, duyarlılık, kesinlik, özgüllük ve F₁ ölçütü sırasıyla %78.57, %100, %53.85, %71.43 ve %83.33 ile en yüksek değerlere sahiptir.

Tablo 5.11. k-NN Model III bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.7381	0.9778	0.4615	0.6769	0.8000
50	0.7738	1.0000	0.5128	0.7031	0.8257
75	0.7857	1.0000	0.5385	0.7143	0.8333
100	0.7738	0.9778	0.5385	0.7097	0.8224
125	0.7619	0.9556	0.5385	0.7049	0.8113
150	0.7500	0.9333	0.5385	0.7000	0.8000
175	0.7143	0.8667	0.5385	0.6842	0.7647
200	0.5357	1.0000	0.0000	0.5357	0.6977
225	0.5357	1.0000	0.0000	0.5357	0.6977
250	0.5357	1.0000	0.0000	0.5357	0.6977
272	0.5357	1.0000	0.0000	0.5357	0.6977

Tablo 5.12’de Cosine k-NN modeline ait sonuçlar verilmektedir. Doğruluk, duyarlılık ve özgüllük değerlerinin 25 ve 50 öznitelik sayısında sabit kaldığı görülmektedir. Ancak, 75 öznitelik sayısında özgüllük değerinin düştüğü, 100 ve 125 öznitelik sayısında duyarlılık ve özgüllük değerlerinin dalgalandığı ifade edilebilir. Kesinlik değeri ise öznitelik sayısının artmasıyla birlikte genellikle düşmektedir. F₁ ölçütü ise 25 ve 50 öznitelik sayısında en yüksek değerlere sahiptir ve sonraki değerlerde düşüş eğilimindedir. En iyi performansı sağlayan öznitelik sayısının 25 ve 50 olduğu söylenebilir. Bu durumlarda, doğruluk, duyarlılık, özgüllük, kesinlik ve F₁ sırasıyla ölçütü %85.71, %93.33, %76.92, %82.32 ve %87.5 ile en yüksek değerlere sahiptir.

Tablo 5.12. k-NN Model IV bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8571	0.9333	0.7692	0.8235	0.8750
50	0.8571	0.9333	0.7692	0.8235	0.8750
75	0.8333	0.9333	0.7179	0.7925	0.8571
100	0.8452	0.9778	0.6923	0.7857	0.8713
125	0.8452	0.9556	0.7179	0.7963	0.8687
150	0.8333	0.9556	0.6923	0.7818	0.8600
175	0.8571	0.9556	0.7436	0.8113	0.8776
200	0.5357	1.0000	0.0000	0.5357	0.6977
225	0.5357	1.0000	0.0000	0.5357	0.6977
250	0.5357	1.0000	0.0000	0.5357	0.6977
272	0.5357	1.0000	0.0000	0.5357	0.6977

Tablo 5.13'te Kübik k-NN modeline ait sonuçlar verilmektedir. Tabloya göre doğruluğun öznitelik sayısının artması ile düştüğü, özgüllük değerinin arttığı, duyarlılığın yüksek ve sabit kaldığı, kesinlik metriğinin dalgalı değerlere sahip olduğu ve F₁ ölçütünün genellikle öznitelik sayısının artmasıyla düştüğü söylenebilir. En iyi performansı sağlayan öznitelik sayısının 175 olduğu ifade edilebilir. Bu durumda, doğruluk, duyarlılık, kesinlik ve F₁ ölçütünün sırasıyla %83.33, %97.78, %77.19 ve %86.27 ile en yüksek değerlere sahip olduğu ve özgüllük değerinin de %66.67 ile diğer metriklerle göre düşük olsa da kabul edilebilir düzeyde olduğu söylenebilir.

Tablo 5.13. k-NN Model V bulguları


Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.7976	0.9556	0.6154	0.7414	0.8350
50	0.7857	0.9778	0.5641	0.7213	0.8302
75	0.8095	0.9778	0.6154	0.7458	0.8462
100	0.7857	0.9778	0.5641	0.7213	0.8302
125	0.7976	0.9778	0.5897	0.7333	0.8381
150	0.7857	0.9778	0.5641	0.7213	0.8302
175	0.8333	0.9778	0.6667	0.7719	0.8627
200	0.5357	1.0000	0.0000	0.5357	0.6977
225	0.5357	1.0000	0.0000	0.5357	0.6977
250	0.5357	1.0000	0.0000	0.5357	0.6977
272	0.5357	1.0000	0.0000	0.5357	0.6977

Tablo 5.14'te k-NN Model VI'ya ait sonuçlar verilmektedir. Tabloya göre doğruluk değeri 175 öznitelik sayısına göre genellikle sabit ve yüksek, bu değerden sonra ise sabit ve düşük kaldığı görülmektedir. 200 ve üzerindeki öznitelik sayısında duyarlılık dışındaki tüm metriklerin sabit bir şekilde düşük değerlerde olduğu görülmektedir. En iyi performansın sağlandığı öznitelik sayısının 50 olduğu ifade edilebilir. Bu durumda %80.36 ile kesinlik hariç doğruluk, duyarlılık, özgüllük ve F_1 ölçütü %86.9, %100, %71.79 ve %89.11 ile en yüksek değerlere sahiptir. Kesinlik ise en yüksek değerini 175 öznitelik sayısında %82.69 ile almıştır. 175 öznitelik sayısında da benzer performans değerleri elde edilmiştir. Ancak 50 öznitelik sayısı daha düşük boyutlu bir modeli tercih etmek açısından daha avantajlı olabilir.

Tablo 5.14. k-NN Model VI bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F_1 ölçütü
25	0.8333	0.9778	0.6667	0.7719	0.8627
50	0.8690	1.0000	0.7179	0.8036	0.8911
75	0.8571	1.0000	0.6923	0.7895	0.8824
100	0.8571	1.0000	0.6923	0.7895	0.8824
125	0.8571	0.9778	0.7179	0.8000	0.8800
150	0.8571	0.9778	0.7179	0.8000	0.8800
175	0.8690	0.9556	0.7692	0.8269	0.8866
200	0.5357	1.0000	0.0000	0.5357	0.6977
225	0.5357	1.0000	0.0000	0.5357	0.6977
250	0.5357	1.0000	0.0000	0.5357	0.6977
272	0.5357	1.0000	0.0000	0.5357	0.6977

k-NN sınıflandırıcıları için ROC eğrileri Şekil 5.7'de yer almaktadır. En yüksek AUC değeri KNN Model VI'da 0.9510 olarak bulunmuştur. Diğer modeller için ise sırasıyla 0.8513, 0.9205, 0.912, 0.912 ve 0.9313 değerlerindedir.



Şekil 5.7. k-NN sınıflandırıcıları için ROC eğrileri

5.6. Destek Vektör Makineleri Sınıflandırıcısına Ait Bulgular

Çalışmada SVM sınıflandırıcısı kullanılarak altı farklı model oluşturulmuş ve analiz işlemi yapılmıştır. SVM sınıflandırıcısına ait bulgular Tablo 5.15, Tablo 5.16, Tablo 5.17, Tablo 5.18, Tablo 5.19 ve Tablo 5.20’de yer almaktadır. Tablo 5.15’te Doğrusal Kernelli SVM modeline ait sonuçlar verilmektedir. Tez çalışmasındaki en yüksek doğruluk değeri %94.05 ile bu SVM modelinde bulunmuştur. Farklı öznitelik sayılarına göre doğruluk ve duyarlılık değerleri genel olarak yüksek ve sabit kalmıştır. 200 ve üzerindeki öznitelik sayısında duyarlılık dışındaki metrik değerleri düşmüştür. Bu değere kadar özgüllük, keskinlik ve F_1 ölçütü değerleri öznitelik sayısının artmasıyla artmıştır. Bu bilgiler doğrultusunda, en iyi performansı sağlayan öznitelik sayısının 50 olduğu ve doğruluk, duyarlılık, özgüllük, kesinlik ve F_1 ölçütü sırasıyla %94.05, %95.56, %92.31, %93.48 ve %94.51 ile en yüksek değerlere sahip olduğu söylenebilir. 175 öznitelik sayısında da benzer performans değerleri elde edilmiştir. Ancak 50 öznitelik sayısının daha düşük boyutlu bir modeli tercih etmek açısından daha avantajlı olduğu, 200 ve sonraki öznitelik sayılarında performansın belirgin bir şekilde düştüğü görülmektedir.

Tablo 5.15. SVM Model I bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.9048	0.9556	0.8462	0.8776	0.9149
50	0.9405	0.9556	0.9231	0.9348	0.9451
75	0.9286	0.9556	0.8974	0.9149	0.9348
100	0.9286	0.9556	0.8974	0.9149	0.9348
125	0.9286	0.9556	0.8974	0.9149	0.9348
150	0.9167	0.9556	0.8718	0.8958	0.9247
175	0.9286	0.9556	0.8974	0.9149	0.9348
200	0.5595	0.9333	0.1282	0.5526	0.6942
225	0.5595	0.9333	0.1282	0.5526	0.6942
250	0.5595	0.9333	0.1282	0.5526	0.6942
272	0.5476	0.9111	0.1282	0.5467	0.6833

Tablo 5.16’da ve Tablo 5.17’de Kuadratik ve Kübik Kernelli SVM modellerine ait sonuçlar verilmektedir. Her iki tabloda da aynı bulgular bulunmuştur. Tablodaki verilere göre, öznitelik sayısı 200’e kadar arttıkça doğruluk, özgüllük, kesinlik ve F₁ ölçütünün sabit bir değere yakın kaldığı, bu değerden sonra ise önemli bir düşüş yaşadığı ifade edilebilir. Duyarlılık değerlerinin ise öznitelik sayısının artması ile neredeyse sabit kaldığı söylenebilir. Bu verilere dayanarak, öznitelik sayısının 175 olduğu durumda en yüksek performans elde edildiği görülmektedir. Bu durumda metrik değerleri sırasıyla %89.29, %91.11, %87.18, %89.13 ve %90.11’dir. Öznitelik sayısı 200’den sonra performans metriklerinin değerleri belirgin şekilde düşmüştür.

Tablo 5.16. SVM Model II bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8452	0.9556	0.7179	0.7963	0.8687
50	0.8333	0.8889	0.7692	0.8163	0.8511
75	0.8690	0.9333	0.7949	0.8400	0.8842
100	0.8571	0.9111	0.7949	0.8367	0.8723
125	0.8690	0.9333	0.7949	0.8400	0.8842
150	0.8690	0.9111	0.8205	0.8542	0.8817
175	0.8929	0.9111	0.8718	0.8913	0.9011
200	0.5595	0.9333	0.1282	0.5526	0.6942
225	0.5476	0.9111	0.1282	0.5467	0.6833
250	0.5476	0.9111	0.1282	0.5467	0.6833
272	0.5476	0.9111	0.1282	0.5467	0.6833

Tablo 5.17. SVM Model III bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8452	0.9556	0.7179	0.7963	0.8687
50	0.8333	0.8889	0.7692	0.8163	0.8511
75	0.8690	0.9333	0.7949	0.8400	0.8842
100	0.8571	0.9111	0.7949	0.8367	0.8723
125	0.8690	0.9333	0.7949	0.8400	0.8842
150	0.8690	0.9111	0.8205	0.8542	0.8817
175	0.8929	0.9111	0.8718	0.8913	0.9011
200	0.5595	0.9333	0.1282	0.5526	0.6942
225	0.5476	0.9111	0.1282	0.5467	0.6833
250	0.5476	0.9111	0.1282	0.5467	0.6833
272	0.5476	0.9111	0.1282	0.5467	0.6833

Tablo 5.18’de Medium Gaussian Kernelli SVM modeline ait sonuçlar verilmektedir. Tabloya göre en yüksek doğruluk değeri %92.86 ile 50 öznitelğin kullanıldığı analizde bulunmuştur. Bu öznitelik sayısında duyarlılık, özgüllük, kesinlik ve F₁ ölçütü sırasıyla %95.56, %89.74, %91.49 ve %93.48 ile en yüksek değerlerindedir. Öznitelik sayısı 200 ve üzerinde duyarlılık dışındaki metrik değerlerinde önemli düşüş olduğu da söylenebilir.

Tablo 5.18. SVM Model IV bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8810	0.9111	0.8462	0.8723	0.8913
50	0.9286	0.9556	0.8974	0.9149	0.9348
75	0.9167	0.9556	0.8718	0.8958	0.9247
100	0.9167	0.9333	0.8974	0.9130	0.9231
125	0.8929	0.9111	0.8718	0.8913	0.9011
150	0.8810	0.8889	0.8718	0.8889	0.8889
175	0.8810	0.9111	0.8462	0.8723	0.8913
200	0.5476	0.9111	0.1282	0.5467	0.6833
225	0.5476	0.9111	0.1282	0.5467	0.6833
250	0.5476	0.9111	0.1282	0.5467	0.6833
272	0.5476	0.9111	0.1282	0.5467	0.6833

Tablo 5.19’da Gauss Kernelli SVM Model V’e ait sonuçlar verilmektedir. Öznitelik sayısının artmasıyla tablodaki metrik değerleri de genellikle sabit kalmıştır. 50, 75, 100, 125, 150 ve 175 öznitelik sayısında değerler sabit ve yüksektir. Doğruluk,

duyarlılık, özgüllük, kesinlik ve F_1 ölçütü değerleri sırasıyla %88.1, %95.56, %79.49, %84.31 ve %89.58'dir. Bu modelde de öznitelik sayısının 200 ve üzeri olduğu durumlarda performans düşüşü söz konusudur.

Tablo 5.19. SVM Model V bulguları


Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F_1 ölçütü
25	0.8571	0.9111	0.7949	0.8367	0.8723
50	0.8810	0.9556	0.7949	0.8431	0.8958
75	0.8810	0.9556	0.7949	0.8431	0.8958
100	0.8810	0.9556	0.7949	0.8431	0.8958
125	0.8810	0.9556	0.7949	0.8431	0.8958
150	0.8810	0.9556	0.7949	0.8431	0.8958
175	0.8810	0.9556	0.7949	0.8431	0.8958
200	0.5357	0.9111	0.1026	0.5395	0.6777
225	0.5476	0.9111	0.1282	0.5467	0.6833
250	0.5476	0.9111	0.1282	0.5467	0.6833
272	0.5476	0.9111	0.1282	0.5467	0.6833

Tablo 5.20'de Fine Gaussian Kernelli SVM modeline ait sonuçlar verilmektedir. Bu model diğer modellere kıyasla en düşük performansın görüldüğü model olmuştur. Tüm öznitelik sayılarında eşit değerler bulunmuş ve metrikler sırasıyla %53.57, %100, %0, %53.57 ve %69.77 olarak elde edilmiştir.

Tablo 5.20. SVM Model VI bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F_1 ölçütü
Tüm kombinasyonlar	0.5357	1.0000	0	0.5357	0.6977

SVM sınıflandırıcıları için ROC eğrileri Şekil 5.8'de yer almaktadır. En yüksek AUC değeri SVM Model I'de 0.9698 olarak bulunmuştur. Diğer modeller için ise sırasıyla 0.9368, 0.910, 0.9681, 0.9567 ve 0.8638 değerleri elde edilmiştir.



Şekil 5.8. SVM sınıflandırıcıları için ROC eğrileri

5.7. Yapay Sinir Ağları Sınıflandırıcısına Ait Bulgular

Çalışmada ANN sınıflandırıcısı kullanılarak beş farklı model oluşturulmuş ve analiz işlemi yapılmıştır. ANN sınıflandırıcısına ait bulgular Tablo 5.21, Tablo 5.22, Tablo 5.23, Tablo 5.24 ve Tablo 5.25'te yer almaktadır. Tablo 5.21'de Narrow ANN modeline ait sonuçlar verilmektedir. Tablodaki verilere göre, en yüksek doğruluk değeri 175 öznitelik sayısında (%85.71) elde edilmiştir. Duyarlılık değeri en yüksek olan 225, 250 ve 272 öznitelik sayılarında (%95.56) aynı değeri göstermektedir. Özgüllük, kesinlik ve F_1 ölçütü için en yüksek değerleri öznitelik sayısının 175 olduğu durumda elde edilmiştir. Bu değerde metrik değerleri %87.18, %88.37 ve %86.36'dır. En düşük doğruluk değeri 200, 225, 250 ve 272 öznitelik sayılarında (%54.76) görülmüştür. Duyarlılık değeri en düşük olan öznitelik sayısı 100 (%82.22) olarak, en düşük özgüllük değeri 225 ve 272 öznitelik sayılarında (%7.69) elde edilmiştir. Kesinlik ve F_1 ölçütü değerlerinin en düşük olduğu öznitelik sayısı 200 (%54.55, %68.85) olarak bulunmuştur.

Tablo 5.21. ANN Model I bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.7738	0.8667	0.6667	0.7500	0.8041
50	0.8452	0.8444	0.8462	0.8636	0.8539
75	0.8214	0.8667	0.7692	0.8125	0.8387
100	0.8095	0.8222	0.7949	0.8222	0.8222
125	0.8452	0.9111	0.7692	0.8200	0.8632
150	0.7857	0.8444	0.7179	0.7755	0.8085
175	0.8571	0.8444	0.8718	0.8837	0.8636
200	0.5476	0.9333	0.1026	0.5455	0.6885
225	0.5476	0.9556	0.0769	0.5443	0.6935
250	0.5595	0.9556	0.1026	0.5513	0.6992
272	0.5476	0.9556	0.0769	0.5443	0.6935

Tablo 5.22’de Medium ANN modeline ait sonuçlar verilmektedir. Tablodaki verilere göre, öznitelik sayısı 200’e kadar arttıkça doğruluk, özgüllük, kesinlik ve F₁ ölçütünün sabit bir değere yakın kaldığı, bu değerden sonra ise önemli bir düşüş yaşadığı ifade edilebilir. Duyarlılık değerlerinin ise öznitelik sayısının artması ile neredeyse sabit kaldığı söylenebilir. Bu verilere dayanarak, öznitelik sayısının 100 ile 125 olduğu durumlarda en yüksek performans elde edildiği görülmektedir. Bu durumda metrik değerleri sırasıyla %86.9, %93.33, %79.49, %84.0 ve %88.42’dir. Öznitelik sayısının 200 ve üzerinde olduğu durumlarda performans belirgin şekilde düşmüştür.

Tablo 5.22. ANN Model II bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8214	0.9333	0.6923	0.7778	0.8485
50	0.8810	0.8889	0.8718	0.8889	0.8889
75	0.8214	0.8667	0.7692	0.8125	0.8387
100	0.8690	0.9333	0.7949	0.8400	0.8842
125	0.8690	0.9333	0.7949	0.8400	0.8842
150	0.8571	0.8222	0.8974	0.9024	0.8605
175	0.8571	0.8889	0.8205	0.8511	0.8696
200	0.5595	0.9333	0.1282	0.5526	0.6942
225	0.5476	0.9333	0.1026	0.5455	0.6885
250	0.5476	0.9333	0.1026	0.5455	0.6885
272	0.5476	0.9333	0.1026	0.5455	0.6885

Tablo 5.23'te Wide ANN modeline ait sonuçlar verilmektedir. Verilere göre, 175 öznitelikli bir model en yüksek doğruluk (0.9286), duyarlılık (0.9556), özgüllük (0.8974), kesinlik (0.9149) ve F_1 ölçütü (0.9348) değerlerine sahiptir. Bu model, en iyi performansı sergilemektedir. Ancak, 225, 250 ve 272 öznitelikli modellerin performansı diğerlerine göre oldukça düşüktür. Doğruluk, duyarlılık, özgüllük, kesinlik ve F_1 ölçütü değerleri düşüktür. Bu modellerin öznitelik sayısının artması performansı olumsuz yönde etkilemiş gibi görünmektedir. Tablodaki verilere göre, 75 öznitelikli bir modelin performansı da oldukça yüksektir ve 175 öznitelikli modele yakın değerlere sahiptir.

Tablo 5.23. ANN Model III bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F_1 ölçütü
25	0.8452	0.9333	0.7436	0.8077	0.8660
50	0.8452	0.8889	0.7949	0.8333	0.8602
75	0.8810	0.9111	0.8462	0.8723	0.8913
100	0.8929	0.9111	0.8718	0.8913	0.9011
125	0.8929	0.9333	0.8462	0.8750	0.9032
150	0.8690	0.8889	0.8462	0.8696	0.8791
175	0.9286	0.9556	0.8974	0.9149	0.9348
200	0.8333	0.7111	0.9744	0.9697	0.8205
225	0.5476	0.9333	0.1026	0.5455	0.6885
250	0.5476	0.9333	0.1026	0.5455	0.6885
272	0.5476	0.9333	0.1026	0.5455	0.6885

Tablo 5.24'te Bilayered ANN modeline ait sonuçlar verilmektedir. Tabloya göre, 150 özniteliğin kullanıldığı analiz en iyi performansın olduğu analizdir. Bu model en yüksek doğruluk (0.8810), duyarlılık (0.9111), özgüllük (0.8462), kesinlik (0.8723) ve F_1 ölçütü (0.8913) değerlerine sahiptir. 200 üzeri özniteliğin yer aldığı analizlerde ise performans düşüklüğü söz konusudur. 25, 50, 75 ve 100 öznitelikli modellerin performansı birbirine benzerdir ve diğer modellere göre daha iyi bir performans sergilemektedir.

Tablo 5.24. ANN Model IV bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8333	0.8889	0.7692	0.8163	0.8511
50	0.8810	0.8667	0.8974	0.9070	0.8864
75	0.8333	0.8889	0.7692	0.8163	0.8511
100	0.8333	0.9111	0.7436	0.8039	0.8542
125	0.8452	0.8222	0.8718	0.8810	0.8506
150	0.8810	0.9111	0.8462	0.8723	0.8913
175	0.8214	0.8222	0.8205	0.8409	0.8315
200	0.5238	0.9111	0.0769	0.5325	0.6721
225	0.5476	0.9333	0.1026	0.5455	0.6885
250	0.5357	0.9111	0.1026	0.5395	0.6777
272	0.5476	0.9111	0.1282	0.5467	0.6833


Tablo 5.25'te üç katmanlı ANN modeline ait sonuçlar verilmektedir. Tablodaki verilere göre 125 öznitelikli bir model en yüksek doğruluk (0.9048), duyarlılık (0.8889), özgüllük (0.9231), kesinlik (0.9302) ve F₁ ölçütü (0.9091) değerlerine sahiptir. Diğer sınıflandırıcılarda da görüldüğü gibi 200 üzeri öznitelik sayısının yer aldığı analizlerde bu sınıflandırıcı modelinin de performansı düşmektedir. 25, 50, 75 ve 100 öznitelikli modellerin performansı birbirine benzerdir ve diğer modellere göre daha iyi bir performans sergilediği ifade edilebilir.

Tablo 5.25. ANN Model V bulguları

Öznitelik Sayısı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü
25	0.8214	0.8889	0.7436	0.8000	0.8421
50	0.8095	0.8889	0.7179	0.7843	0.8333
75	0.8333	0.8667	0.7949	0.8298	0.8478
100	0.8095	0.8222	0.7949	0.8222	0.8222
125	0.9048	0.8889	0.9231	0.9302	0.9091
150	0.8452	0.9111	0.7692	0.8200	0.8632
175	0.8333	0.8222	0.8462	0.8605	0.8409
200	0.5357	0.9111	0.1026	0.5395	0.6777
225	0.5595	0.9778	0.0769	0.5500	0.7040
250	0.5357	0.9333	0.0769	0.5385	0.6829
272	0.5119	0.9111	0.0513	0.5256	0.6667

ANN sınıflandırıcıları için ROC eğrileri Şekil 5.9'da yer almaktadır. En yüksek AUC değeri ANN Model III'te 0.9701 olarak bulunmuştur. Bu tez çalışmasında

bulunan en yüksek değerdir. Diğer ANN modelleri için ise sırasıyla 0.9698, 0.9208, 0.9499 ve 0.9407 değerleri elde edilmiştir.



Şekil 5.9. ANN sınıflandırıcıları için ROC eğrileri

5.8. İris Öz niteliklerine Fizyolojik Parametrelerin Eklenmesi ile Performans Ölçümleri

Sadece iris öz niteliklerinin yer aldığı sınıflandırıcı ailelerinden en iyi performansı sağlayan modellere ait metrikler Tablo 5.26’da yer almaktadır. Tablodaki metrik değerlerine göre beş sınıflandırıcı modelinin de yüksek performansa sahip olduğu ifade edilebilir. Doğruluk, özgüllük, kesinlik ve F_1 ölçütü metriklerine göre SVM sınıflandırıcısı en iyi performansa sahiptir. Duyarlılık için k-NN en başarılı iken AUC değeri için ANN sınıflandırıcısı en iyi konumdadır.

Tablo 5.26. Sınıflandırıcıların karşılaştırmalı analizi

Sınıflandırıcı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F_1 ölçütü	AUC
NB	0.8929	0.9556	0.8205	0.8600	0.9053	0.9373
DT	0.8810	0.8667	0.8974	0.9070	0.8864	0.8721
k-NN	0.8690	1.0000	0.7179	0.8036	0.8911	0.9510
SVM	0.9405	0.9556	0.9231	0.9348	0.9451	0.9698
ANN	0.9286	0.9556	0.8974	0.9149	0.9348	0.9701

Tablo 5.27. Fizyolojik özniteliklerin eklenmesi sonucu oluşan metrik değerleri

Sınıflandırıcı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F ₁ ölçütü	AUC
NB	0.9048	0.9778	0.8205	0.8627	0.9167	0.9721
DT	0.8929	0.8889	0.8974	0.9091	0.8989	0.8818
k-NN	0.8929	1.0000	0.7692	0.8333	0.9091	0.9479
SVM	0.9524	0.9556	0.9487	0.9556	0.9556	0.9812
ANN	0.9405	0.9556	0.9231	0.9348	0.9451	0.9647

Tablo 5.27’de en yüksek sınıflandırıcı performansına ait modellere gönüllülerin fizyolojik özniteliklerinin eklenmesi sonucunda oluşan performans metrikleri yer almaktadır. Tablodaki metriklerde fizyolojik özniteliklerin ilave edilmesiyle ortaya çıkan önemli artışlar göze çarpmaktadır. ANN modelinin AUC değeri haricinde tüm metrik değerlerinin yükseldiği görülmektedir.

Tablo 5.3 ve Tablo 5.27 arasındaki bulgular ile literatürdeki iris görüntülerinden kalp hastalığı teşhisi üzerine yapılan çalışmaların karşılaştırmalı değerleri Tablo 5.28’de listelenmiştir. Tabloda mevcut çalışmalarda kullanılan özellik çıkarma yöntemleri, sınıflandırıcı isimleri ve değerlendirme metrikleri yer almaktadır.

Mevcut çalışmalar arasında Gunawan ve ark. GLCM öznitelikleri ile SVM sınıflandırıcısını kullanarak %91 doğruluk elde etmiştir. Putra ve ark. aynı özellik çıkarma yöntemiyle Yapay Sinir Ağı kullanarak %78 doğruluk değerine ulaşmış ve PCA yöntemiyle de %90 başarı elde etmişlerdir. Kusuma ve ark. ile Permatasari ve ark. öznitelik çıkarımı için sırasıyla Siyah Beyaz Oranı ve PCA yöntemlerini kullanmış, sınıflandırma işlemini ise sırasıyla Eşikleme ve SVM yöntemleri ile gerçekleştirmiştir. Bu çalışmalarda doğruluk değerleri sırasıyla %83 ve %80 bulunmuş, doğruluk dışında performans ölçütlerine yer verilmemiştir. 94 KAH ve 104 Kontrol grubunun olduğu önceki çalışmamızda ise bir seviye dalgacık dönüşümü temelli istatistiksel, GLCM ve GLRLM özellikleri ve beş farklı sınıflandırıcı kullanılarak SVM sınıflandırıcısı ile diğer çalışmalara kıyasla %93 gibi daha yüksek bir doğruluk değeri elde edilmiştir.

Tablo 5.28. Mevcut çalışmalarla karşılaştırma tablosu

Yazar ve Referans	Öznitelik Çıkarma	Sınıflandırıcı	Performans Metrik Değerleri					
			ACC	SNS	SPC	PRC	F ₁	AUC
(Gunawan vd., 2022)	GLCM	SVM	0.91	-	-	-	-	-
(Putra vd., 2018)	GLCM	ANN	0.78	-	-	-	-	-
	PCA	ANN	0.90	-	-	-	-	-
(Kusuma vd., 2018)	Siyah-Beyaz Oranı	Eşikleme	0.83	-	-	-	-	-
(Permatasari vd., 2016)	PCA	SVM	0.80	-	-	-	-	-
Önceki Çalışma (Özbilgin vd., 2023)	1 seviye DWT ve İstatistiksel, GLCM ve GLRLM öznitelikleri	k-NN	0.90	0.92	0.88	0.85	0.88	0.94
		NB	0.90	0.88	0.91	0.88	0.88	0.98
		SVM	0.93	1.00	0.88	0.86	0.93	0.96
		DT	0.88	0.84	0.91	0.88	0.86	0.87
		ANN	0.92	0.96	0.88	0.86	0.91	0.92
Bu çalışma	2 seviye DWT ve İstatistiksel, GLCM ve GLRLM öznitelikleri	k-NN	0.87	1.00	0.72	0.80	0.89	0.95
		NB	0.89	0.96	0.82	0.86	0.91	0.94
		SVM	0.94	0.96	0.92	0.93	0.95	0.97
		DT	0.88	0.87	0.90	0.91	0.89	0.87
		ANN	0.93	0.96	0.90	0.91	0.94	0.97
Bu çalışma	2 seviye DWT ve İstatistiksel, GLCM, GLRLM ve fizyolojik öznitelikler	k-NN	0.89	1.00	0.77	0.83	0.91	0.95
		NB	0.90	0.98	0.82	0.86	0.92	0.97
		SVM	0.95	0.96	0.95	0.96	0.96	0.98
		DT	0.89	0.89	0.90	0.91	0.90	0.88
		ANN	0.94	0.96	0.92	0.93	0.95	0.96

Bu tez çalışmasında ise 155 KAH ve 126 Kontrol grubuna ait iris görüntüleri kullanılmıştır. İki seviye dalgacık dönüşümü uygulanarak görüntü 8 alt bileşene ayrılmış ve bu bileşenlere ait istatistiksel, GLCM ve GLRLM öznitelikleri çıkarılmıştır. Toplamda 272 öznitelik elde edilmiş ve ReliefF öznitelik seçme yöntemi uygulanmıştır. k-NN, NB, SVM, DT ve ANN sınıflandırıcı ailelerine ait modeller ile sınıflandırma gerçekleştirilmiş ve SVM ile %94.05’lik doğruluk performansı elde

edilmiştir. Bu değer iris özniteliklerinin kullanıldığı mevcut çalışmalar arasındaki en yüksek doğruluk değeridir. İris özniteliklerine fizyolojik öznitelikler eklendiğinde ise performans değerinin arttığını gözlemlenmiştir. Doğruluk değeri %95.24'e çıkarak en yüksek değerini elde etmiştir. Doğruluk değerinin yanı sıra duyarlılık, özgüllük, kesinlik, F_1 ölçütü ve AUC gibi performans ölçümleri de hem sadece iris özniteliklerinin hem de iris ve fizyolojik özniteliklerin birlikte kullanıldığı analizlerin KAH'ı başarılı bir şekilde tespit ettiğini göstermektedir.



6. SONUÇLAR VE ÖNERİLER

6.1. Sonuçlar

Bu çalışma, 281 gönüllünün iris görüntülerinden Koroner Arter Hastalığını tespit etmek için invazif olmayan bir yöntem önermektedir. Gönüllülere ait göz görüntüleri ilk olarak görüntü ön-işleme sürecinden geçmektedir. Bu süreçte Daugman'ın IDO yöntemi ile iris iç ve dış sınırlarının bulunması, Daugman'ın Rubber Sheet tekniği ile irisin dikdörtgen formata standardizasyonu, iridoloji haritasına göre iristeki kalp konumunun bulunması ve adaptif histogram eşitleme yöntemi ile analiz bölgesinin görüntü iyileştirmesi yer almaktadır. İris ön işleme süreçlerinden sonra, analiz bölgesine iki seviye dalgacık dönüşümü uygulanarak elde edilen sekiz alt bileşenden toplam 272 istatistiksel, GLCM ve GLRLM özelliği çıkarılmıştır. Sınıflandırma öncesinde en iyi 25, 50, 75, 100, 125, 150, 175, 200, 225, 250 ve 272 özniteliği belirlemek için ReliefF özellik seçim süreci kullanılmıştır. Sınıflandırma aşaması beş ana sınıflandırıcı ailesinden olan 22 sınıflandırıcı kullanılmıştır. Sınıflandırma işleminde 10-katlı çapraz doğrulama tekniği uygulanmış ve test verilerine ait performansı değerlendirmek için doğruluk, duyarlılık, özgüllük, kesinlik, F_1 ölçütü ve AUC metriklerine ait ortalama değerleri kullanılmıştır.

Doğruluk metriği için Doğrusal kernelli SVM yöntemine ait modelde %94.05 ile en yüksek değer elde edilmiştir. SVM'yi %92.86 ile ANN, %89.29 ile NB, %88.1 ile DT ve son olara da %86.9 ile k-NN sınıflandırıcısı izlemektedir. SVM yöntemi özgüllük, kesinlik ve F_1 ölçütü metriklerinde de sırasıyla %92.31, %93.48 ve %94.51 ile en iyi sonucu vermiştir. Duyarlılık metriğinde %100 ile k-NN en iyi sınıflandırıcı olurken ANN'ye ait modelde AUC değeri %97.01 ile en başarılı model olmuştur.

İris özniteliklerine gönüllülere ait biyodemografik parametreler de eklenerek analizler yapılmıştır. Bu parametrelerin eklenmesiyle neredeyse tüm metrik değerlerinde artış görülmüştür. Doğruluk metriği SVM için %95 ile en yüksek değerine ulaşmıştır. ANN %94 ile ikinci en yüksek olurken, NB, k-NN ve DT sınıflandırıcılarında bulunan değerler sırasıyla %90, %89 ve %89'dur. SVM modelinde, özgüllük, kesinlik, F_1 ölçütü ve AUC metriklerinde de sırasıyla %95, %96, %96 ve %98 ile en iyi sonucu vermiştir. Duyarlılık metriğinde %100 ile yine k-NN en iyi sınıflandırıcı konumundadır.

Elde edilen bulgulara göre çalışmada kullanılan tüm sınıflandırıcıların doğruluk ve diğer metrik değerleri göz önüne alınarak iristen KAH tespiti için başarılı sonuçlar verdiği söylenebilir.

6.2. Öneriler

Bu çalışma, iris görüntülerinden KAH tespiti için bir referans sağlamaktadır. Önerilen yöntem, teletıp sistemlerinde koroner arter hastalığına yönelik telediagnostik uygulamaları desteklemek için kullanılabilir. Böylece, günlük klinik uygulamaları gerçekleştirmeden önce bir ön değerlendirme yapmak amacıyla hastanın iris görüntüleri kullanılarak KAH hakkında bilgi edinilebilir.

Gelecek çalışmalarda kalp yetmezliği ve ritim bozukluğu gibi çeşitli kalp hastalıklarının iris analizi ile ilişkisi incelenebilir. Farklı öznetelik çıkarma ve makine öğrenimi yöntemleri denenerek ve konvolüsyonel sinir ağları kullanılarak çeşitli hastalıklar tespiti ve performans iyileştirmesi yapılabilir.

KAYNAKLAR

- Abdelrahman, K. M., Chen, M. Y., Dey, A. K., Virmani, R., Finn, A. V., Khamis, R. Y., . . . Buckler, A. J. (2020). Coronary computed tomography angiography from clinical uses to emerging technologies: JACC state-of-the-art review. *Journal of the American College of Cardiology*, 76(10), 1226-1243.
- Abidin, Z. Z. (2021). *Swarm Intelligence for Iris Recognition*, CRC Press.
- Abu Alfeilat, H. A., Hassanat, A. B., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Eyal Salman, H. S. ve Prasath, V. S. (2019). Effects of distance measure choice on k-nearest neighbor classifier performance: a review. *Big data*, 7(4), 221-248.
- Acharya, R., Ng, Y. E. ve Suri, J. S. (2008). *Image modeling of the human eye*, Artech House.
- Adatia, I., Kothari, S. S. ve Feinstein, J. A. (2010). Pulmonary hypertension associated with congenital heart disease: pulmonary vascular disease: the global perspective. *Chest*, 137(6), 52S-61S.
- Ahmad, M. T., Zhang, P., Dufresne, C., Ferrucci, L. ve Semba, R. D. (2018). The human eye proteome project: updates on an emerging proteome. *Proteomics*, 18(5-6), 1700394.
- Akin, I. ve Nienaber, C. A. (2015). "Obesity paradox" in coronary artery disease. *World journal of cardiology*, 7(10), 603.
- Akman, M. ve Civek, S. (2022). Dünyada ve Türkiye’de kardiyovasküler hastalıkların sıklığı ve riskin değerlendirilmesi. *The Journal of Turkish Family Physician*, 13(1), 21-28.
- Al-Lamee, R. K., Shun-Shin, M. J., Howard, J. P., Nowbar, A. N., Rajkumar, C., Thompson, D., . . . Davies, J. (2019). Dobutamine Stress Echocardiography Ischemia as a Predictor of the Placebo-Controlled Efficacy of Percutaneous Coronary Intervention in Stable Coronary Artery Disease: The Stress Echocardiography–Stratified Analysis of ORBITA. *Circulation*, 140(24), 1971-1980.
- Alizadehsani, R., Zangoeei, M. H., Hosseini, M. J., Habibi, J., Khosravi, A., Roshanzamir, M., . . . Nahavandi, S. (2016). Coronary artery disease detection using computational intelligence methods. *Knowledge-Based Systems*, 109, 187-197.
- Amari, S.-i. ve Wu, S. (1999). Improving support vector machine classifiers by modifying kernel functions. *Neural networks*, 12(6), 783-789.
- Anonim, (2022a). Gözün Yapısı. Erişim adresi <https://gozdoktor.net/gozun-yapisi/> (Erişim tarihi: 01.09.2022)
- Anonymous, (2022a). Iris Muscles. Erişim adresi <https://mammothmemory.net/biology/organs-and-systems/the-eye/antagonistic-muscles.html> (Erişim tarihi: 01.09.2022)
- Armstrong, R. A. ve Cubbidge, R. C. (2019). 1 - The Eye and Vision: An Overview. Victor R. Preedy ve Ronald Ross Watson (Editörler), *Handbook of Nutrition, Diet, and the Eye (Second Edition)* (s. 3-14): Academic Press.

- Bachmann, J. M., Willis, B. L., Ayers, C. R., Khera, A. ve Berry, J. D. (2012). Association between family history and coronary heart disease death across long-term follow-up in men: the Cooper Center Longitudinal Study. *Circulation*, 125(25), 3092-3098.
- Bansal, A., Agarwal, R. ve Sharma, R. (2015). Determining diabetes using iris recognition system. *International journal of diabetes in developing countries*, 35, 432-438.
- Barton, M. (2013). Cholesterol and atherosclerosis: modulation by oestrogen. *Current opinion in lipidology*, 24(3), 214-220.
- Basak, S. K. (2019). *Essentials of ophthalmology*: Jaypee Brothers Medical Publishers.
- Becker Dopke, M. R. ve Battello, C. (2017). *Iridology and Genetics: Express Psychic Biotypes And Pollyallely In The Iris*: Digitaliza.
- Benjamin, E. J., Muntner, P., Alonso, A., Bittencourt, M. S., Callaway, C. W., Carson, A. P., . . . Das, S. R. (2019). Heart disease and stroke statistics—2019 update: a report from the American Heart Association. *Circulation*, 139(10), e56-e528.
- Berdonces, J. L. (2015). *El gran libro de la iridología*: RBA Libros.
- Berry, J. D., Dyer, A., Cai, X., Garside, D. B., Ning, H., Thomas, A., . . . Lloyd-Jones, D. M. (2012). Lifetime risks of cardiovascular disease. *New England Journal of Medicine*, 366(4), 321-329.
- Boileau, M. J. ve Gilmour, M. A. (2012). Chapter 14 - Diseases of the Eye. D. G. Pugh ve A. N. Baird (Editörler), *Sheep and Goat Medicine (Second Edition)* (s. 406-441). Saint Louis: W.B. Saunders.
- Boughton, B. A., Thomas, O. R., Demarais, N. J., Trede, D., Swearer, S. E. ve Grey, A. C. (2020). Detection of small molecule concentration gradients in ocular tissues and humours. *Journal of Mass Spectrometry*, 55(4), e4460.
- Brown, J. C., Gerhardt, T. E. ve Kwon, E. (2020). Risk factors for coronary artery disease.
- Care, D. (2019). Standards of medical care in diabetes 2019. *Diabetes Care*, 42(Suppl 1), S124-138.
- Cassel, G. H. (2021). *The eye book: a complete guide to eye disorders and health*: JHU Press.
- Chandola, T., Britton, A., Brunner, E., Hemingway, H., Malik, M., Kumari, M., . . . Marmot, M. (2008). Work stress and coronary heart disease: what are the mechanisms? *European heart journal*, 29(5), 640-648.
- Che, D., Liu, Q., Rasheed, K. ve Tao, X. (2011). Decision tree and ensemble learning algorithms with their applications in bioinformatics. *Software tools and algorithms for biological systems*, 191-199.
- Chicco, D., Tötsch, N. ve Jurman, G. (2021). The Matthews correlation coefficient (MCC) is more reliable than balanced accuracy, bookmaker informedness, and markedness in two-class confusion matrix evaluation. *BioData mining*, 14(1), 1-22.
- Clausi, D. A. (2002). An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of remote sensing*, 28(1), 45-62.

- Coffey, S., Cairns, B. J. ve Iung, B. (2016). The modern epidemiology of heart valve disease. *Heart*, 102(1), 75-85.
- Dai, W. ve Ji, W. (2014). A mapreduce implementation of C4. 5 decision tree algorithm. *International journal of database theory and application*, 7(1), 49-60.
- Danaei, G., Ding, E. L., Mozaffarian, D., Taylor, B., Rehman, J., Murray, C. J. ve Ezzati, M. (2009). The preventable causes of death in the United States: comparative risk assessment of dietary, lifestyle, and metabolic risk factors. *PLoS medicine*, 6(4), e1000058.
- Daniel, M., Raharjo, J. ve Usman, K. (2020). Iris-based image processing for cholesterol level detection using gray level co-occurrence matrix and support vector machine. *Engineering Journal*, 24(5), 135-144.
- Daugman, J. (2009). How iris recognition works. *The essential guide to image processing* (s. 715-739): Elsevier.
- Diwakar, M., Tripathi, A., Joshi, K., Sharma, A., Singh, P. ve Memoria, M. (2021). A comparative review: Medical image fusion using SWT and DWT. *Materials Today: Proceedings*, 37, 3411-3416.
- Dreyfus, S. E. (1990). Artificial neural networks, back propagation, and the Kelley-Bryson gradient procedure. *Journal of guidance, control, and dynamics*, 13(5), 926-928.
- Dudzinski, D. M., Mak, G. S. ve Hung, J. W. (2012). Pericardial diseases. *Current problems in cardiology*, 37(3), 75-118.
- Ehrlich, R., Harris, A., Wentz, S. M., Moore, N. A. ve Siesky, B. A. (2017). Anatomy and Regulation of the Optic Nerve Blood Flow☆. *Reference Module in Neuroscience and Biobehavioral Psychology*: Elsevier.
- Erdem, Y., Akpolat, T., Derici, Ü., Şengül, Ş., Ertürk, Ş., Ulusoy, Ş., . . . Arıcı, M. (2017). Dietary sources of high sodium intake in Turkey: SALTURK II. *Nutrients*, 9(9), 933.
- Erol, Y. O., Ozogul, C., Elgin, U., Helvacioğlu, F. ve Zilelioglu, O. (2018). Electron Microscopic Investigation of Anterior Lens Capsule and Epithelium in Patients with Diabetes Mellitus. *International Journal of Clinical Medicine*, 9(10), 778.
- Esteves, R. B., Morero, J. A. P., de Souza Pereira, S., Mendes, K. D. S., Hegadoren, K. M. ve Cardoso, L. (2021). Parameters to increase the quality of iridology studies: A scoping review. *European Journal of Integrative Medicine*, 43, 101311.
- Farrell, A. P., Jones, D., Hoar, W. ve Randall, D. (1992). The heart. *The Cardiovascular System*, 12, 1-88.
- Forrester, J. V., Dick, A. D., McMenamin, P. G., Roberts, F. ve Pearlman, E. (2020). *The eye e-book: basic sciences in practice*: Elsevier Health Sciences.
- Fu, Q., Celenk, M. ve Wu, A. (2019). An improved algorithm based on CLAHE for ultrasonic well logging image enhancement. *Cluster Computing*, 22(Suppl 5), 12609-12618.

- Gardner, M. W. ve Dorling, S. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15), 2627-2636.
- Gasson, M., Meints, M. ve Warwick, K. J. F. o. i. i. t. I. S. (2005). A Study on PKI and biometrics.
- Gerçekoğlu, H. (2017). Ateroskleroz (Damar Sertliği). Erişim adresi <https://drhakangercekoglu.com/hastaliklar/ateroskleroz> (Erişim tarihi: 01.09.2022)
- Ghiasi, M. M., Zendehboudi, S. ve Mohsenipour, A. A. (2020). Decision tree-based diagnosis of coronary artery disease: CART model. *Computer methods and programs in biomedicine*, 192, 105400.
- Gökmen, F. G. (2003). Sistematiik anatomi. *İzmir: Güven Kitabevi*, 97(8).
- Görgel, E. B. ve Çakıroğlu, F. P. (2007). Menopoz döneminde kadın. In: Ankara: Ankara Üniversitesi.
- Grabmeier, J. L. ve Lambe, L. A. (2007). Decision trees for binary classification variables grow equally with the Gini impurity measure and Pearson's chi-square test. *International journal of business intelligence and data mining*, 2(2), 213-226.
- Groenewegen, A., Rutten, F. H., Mosterd, A. ve Hoes, A. W. (2020). Epidemiology of heart failure. *European journal of heart failure*, 22(8), 1342-1356.
- Gunawan, V. A., Putra, L. S. A., Imansyah, F. ve Kusumawardhani, E. (2022). Identification of Coronary Heart Disease through Iris using Gray Level Co-occurrence Matrix and Support Vector Machine Classification. *International Journal of Advanced Computer Science and Applications*, 13(1).
- Gül, B. K. (2017). *Kolesterol seviyesi ile iristeki sodyum halkası arasındaki ilişkinin incelenmesi*. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.
- Gürsürer, M. (2023). Kalp Hastalıkları. Erişim adresi <https://metingursurer.com/hastaliklar-ve-tedavi-yontemleri/kalp-hastaliklari> (Erişim tarihi: 01.09.2022)
- Hajar, R. (2017). Risk factors for coronary artery disease: historical perspectives. *Heart views: the official journal of the Gulf Heart Association*, 18(3), 109.
- Haralick, R. M., Shanmugam, K. ve Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*(6), 610-621.
- Hasan, M. K., Alam, M. A., Das, D., Hossain, E. ve Hasan, M. (2020). Diabetes prediction using ensembling of different machine learning classifiers. *IEEE Access*, 8, 76516-76531.
- Hassanabad, A. F., Zarzycki, A., Deniset, J. ve Fedak, P. W. (2021). An Overview of Human Pericardial Space and Pericardial Fluid. *Cardiovascular Pathology*, 107346.
- Hassanat, A. B., Abbadi, M. A., Altarawneh, G. A. ve Alhasanat, A. A. (2014). Solving the problem of the K parameter in the KNN classifier using an ensemble learning approach. *arXiv preprint arXiv:1409.0919*.

- Health, B. A. (2023). Jensen Iridology map. Eriřim adresi <https://boydsalternativehealth.com/> (Eriřim tarihi: 01.09.2022)
- Hopfield, J. J. (1988). Artificial neural networks. *IEEE Circuits and Devices Magazine*, 4(5), 3-10.
- Hussein, S. E., Hassan, O. A. ve Granat, M. H. (2013). Assessment of the potential iridology for diagnosing kidney disease using wavelet analysis and neural networks. *Biomedical Signal Processing and Control*, 8(6), 534-541.
- Iovino, C., Peiretti, E., Braghiroli, M., Tatti, F., Aloney, A., Lanza, M. ve Chhablani, J. (2021). Imaging of iris vasculature: current limitations and future perspective. *Eye*, 1-11.
- Jain, A. K., Mao, J. ve Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Japuntich, S. J., Eilers, M. A., Shenhav, S., Park, E. R., Winickoff, J. P., Benowitz, N. L. ve Rigotti, N. A. (2015). Secondhand tobacco smoke exposure among hospitalized nonsmokers with coronary heart disease. *JAMA internal medicine*, 175(1), 133-136.
- Jensen, B. (2012). *Iridology simplified*: Book Publishing Company.
- Jin, C., De-Lin, L. ve Fen-Xiang, M. (2009). *An improved ID3 decision tree algorithm*. Paper presented at the 2009 4th international conference on computer science & Education.
- José, I. (2018). KNN (K-Nearest Neighbors) #1. Eriřim adresi <https://towardsdatascience.com/knn-k-nearest-neighbors-1-a4707b24bd1d> (Eriřim tarihi: 01.09.2022)
- Justice, L. T., Valley, R. D., Bailey, A. G. ve Hauser, M. W. (2011). CHAPTER 27 - Anesthesia for Ophthalmic Surgery. Peter J. Davis, Franklyn P. Cladis ve Etsuro K. Motoyama (Editörler), *Smith's Anesthesia for Infants and Children (Eighth Edition)* (s. 870-888). Philadelphia: Mosby.
- Kira, K. ve Rendell, L. A. (1992). A practical approach to feature selection. *Machine learning proceedings 1992* (s. 249-256): Elsevier.
- Kononenko, I. (1994). *Estimating attributes: Analysis and extensions of RELIEF*. Paper presented at the European conference on machine learning.
- Koplin, R. S., Ritterband, D. C., Schorr, E., Seedor, J. A. ve Wu, E. (2020). Corneal Surgery: The Cornea—How It Works. *The Scrub's Bible* (s. 145-149): Springer.
- Kozak, J. (2019). *Decision tree and ensemble learning based on ant colony optimization*: Springer.
- Kumar, S. ve Singh, B. K. (2021). DWT based color image watermarking using maximum entropy. *Multimedia Tools and Applications*, 80(10), 15487-15510.
- Kurnaz, Ç. ve Gül, B. K. (2018). İristeki sodyum halkası genişliği ile kolesterol seviyesi arasındaki ilişkinin belirlenmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 33(4), 1557-1568.
- Kusuma, F. D., Kusumaningtyas, E. M., Barakbah, A. R. ve Hermawan, A. A. (2018). *Heart abnormalities detection through iris based on mobile*. Paper presented at

- the 2018 International Electronics Symposium on Knowledge Creation and Intelligent Computing (IES-KCIC).
- Kusumaningtyas, E. M., Barakbah, A. ve Danggriawan, S. (2021). *Diabetes and Heart Disease Identification System Using Iris on the Healthcare Kiosk*. Paper presented at the Journal of Physics: Conference Series.
- Kusumaningtyas, E. M., Barakbah, A. R. ve Hermawan, A. A. (2017). Feature Extraction For Application of Heart Abnormalities Detection Through Iris Based on Mobile Devices. *EMITTER International Journal of Engineering Technology*, 5(2), 312-327.
- Lambert-Cheatham, N., Jusufbegovic, D. ve Corson, T. W. (2021). Intraocular and Orbital Cancers. *Reference Module in Biomedical Sciences*: Elsevier.
- Liao, Y. ve Vemuri, V. R. (2002). Use of k-nearest neighbor classifier for intrusion detection. *Computers & security*, 21(5), 439-448.
- Libby, P. (2021). The changing landscape of atherosclerosis. *Nature*, 592(7855), 524-533.
- Lin, H.-T. (2005). Introduction to Support Vector Machines. *Learning System Group, California Institute of Technology*.
- Lodin, A. ve Demea, S. (2009). *Design of an iris-based medical diagnosis system*. Paper presented at the 2009 International Symposium on Signals, Circuits and Systems.
- Loukas, M., Groat, C., Khangura, R., Owens, D. G. ve Anderson, R. H. (2009). The normal and abnormal anatomy of the coronary arteries. *Clinical Anatomy: The Official Journal of the American Association of Clinical Anatomists and the British Association of Clinical Anatomists*, 22(1), 114-128.
- Luque, A., Carrasco, A., Martín, A. ve de Las Heras, A. (2019). The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216-231.
- Ma, L., Zhang, D., Li, N., Cai, Y., Zuo, W. ve Wang, K. (2012). Iris-based medical analysis by geometric deformation features. *IEEE journal of biomedical and health informatics*, 17(1), 223-231.
- Maciejewicz, A. C. T. (2019). How To Teach An Iris Scanner That The Eye It's Looking At Is Dead. Eriřim adresi <https://spectrum.ieee.org/how-to-teach-an-iris-scanner-that-the-eye-its-looking-at-is-dead> (Eriřim tarihi: 01.09.2022)
- Malakar, A. K., Choudhury, D., Halder, B., Paul, P., Uddin, A. ve Chakraborty, S. (2019). A review on coronary artery disease, its risk factors, and therapeutics. *Journal of cellular physiology*, 234(10), 16812-16823.
- Malkoç, İ. (2006). Göz Küresinin Tabakaları: Anatomik ve Histolojik Bir Derleme. *Eurasian J Med*, 38, 124-129.
- Marchesi, N., Fahmideh, F., Boschi, F., Pascale, A. ve Barbieri, A. (2021). Ocular Neurodegenerative Diseases: Interconnection between Retina and Cortical Areas. *Cells*, 10(9), 2394.
- Martiana, K. E., Barakbah, A. R., Akmilis, S. S. ve Hermawan, A. A. (2016). *Application for heart abnormalities detection through Iris*. Paper presented at the 2016 International Electronics Symposium (IES).

- Mayya, V., Kamath Shevgoor, S., Kulkarni, U., Hazarika, M., Barua, P. D. ve Acharya, U. R. (2021). Multi-scale convolutional neural network for accurate corneal segmentation in early detection of fungal keratitis. *Journal of Fungi*, 7(10), 850.
- McCullough, P. A. (2007). Coronary artery disease. *Clinical Journal of the American Society of Nephrology*, 2(3), 611-616.
- Members, T. F., Montalescot, G., Sechtem, U., Achenbach, S., Andreotti, F., Arden, C., . . . Cuisset, T. (2013). 2013 ESC guidelines on the management of stable coronary artery disease: the Task Force on the management of stable coronary artery disease of the European Society of Cardiology. *European heart journal*, 34(38), 2949-3003.
- Moazed, K. T. (2020). Embryology of Iris. *The Iris* (s. 1-13): Springer.
- Møller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, 6(4), 525-533.
- Mons, U., Müezziner, A., Gellert, C., Schöttker, B., Abnet, C. C., Bobak, M., . . . Kee, F. (2015). Impact of smoking and smoking cessation on cardiovascular events and mortality among older adults: meta-analysis of individual participant data from prospective cohort studies of the CHANCES consortium. *bmj*, 350.
- Mozaffarian, D., Benjamin, E. J., Go, A. S., Arnett, D. K., Blaha, M. J., Cushman, M., . . . Howard, V. J. (2015). Heart disease and stroke statistics—2015 update: a report from the American Heart Association. *Circulation*, 131(4), e29-e322.
- Muzamil, S., Hussain, T., Haider, A., Waraich, U., Ashiq, U. ve Ayguadé, E. (2020). An intelligent iris based chronic kidney identification system. *Symmetry*, 12(12), 2066.
- Ndumele, C. E., Matsushita, K., Lazo, M., Bello, N., Blumenthal, R. S., Gerstenblith, G., . . . Selvin, E. (2016). Obesity and subtypes of incident cardiovascular disease. *Journal of the American Heart Association*, 5(8), e003921.
- Ng, E., Tan, J. H., Acharya, U. R. ve Suri, J. S. (2012). Human eye imaging and modeling.
- Noriega, L. (2005). Multilayer perceptron tutorial. *School of Computing. Staffordshire University*, 4, 5.
- Norn, M. (2003). Analysis of iris: history and future. *Dansk medicinhistorisk arbog*, 103-117.
- Nowbar, A. N., Gitto, M., Howard, J. P., Francis, D. P. ve Al-Lamee, R. (2019). Mortality from ischemic heart disease: Analysis of data from the World Health Organization and coronary artery disease risk factors From NCD Risk Factor Collaboration. *Circulation: cardiovascular quality and outcomes*, 12(6), e005375.
- Noworol, A. (2020). What is the value of iridology as a diagnostic tool. *Med Clin Sci*, 2, 1-6.
- Ogobuiro, I., Wehrle, C. J. ve Tuma, F. (2022). Anatomy, thorax, heart coronary arteries. *StatPearls [Internet]*: StatPearls Publishing.

- Ozbilgin, F. ve Kurnaz, C. (2022). An alternative approach for determining the cholesterol level: Iris analysis. *International Journal of Imaging Systems and Technology*, 32(4), 1159-1171.
- Önal, M. N., Güraksin, G. E. ve Duman, R. (2023). Convolutional neural network-based diabetes diagnostic system via iridology technique. *Multimedia Tools and Applications*, 82(1), 173-194.
- Özbilgin, F. (2019). *Sistemik hastalıkların iristeki belirtilerinin iris analizi yöntemi ile belirlenmesi*. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.
- Özbilgin, F., Kurnaz, Ç. ve Aydın, E. (2023). Prediction of Coronary Artery Disease Using Machine Learning Techniques with Iris Analysis. *Diagnostics*, 13(6), 1081.
- Özdemir, O. (2017). Koroner Arter Dolaşım Sistemi. Erişim adresi <https://drosmanozdemir.com/koroner-arter-dolasim-sistemi/> (Erişim tarihi: 01.09.2022)
- Özdemir, Z. ve Çelik, S. (2018). Kalp kapak hastalıkları cerrahisi ve hemşirelik bakımı. *Turkiye Klinikleri Journal of Surgical Nursing-Special Topics*, 4(1), 26-34.
- Pan, A., Wang, Y., Talaei, M. ve Hu, F. B. (2015). Relation of smoking with total mortality and cardiovascular events among patients with diabetes mellitus: a meta-analysis and systematic review. *Circulation*, 132(19), 1795-1804.
- Panja, M., M., Saha, M., K., Basu, U., Datta, D. ve Mandal, B., N. (2016). Computing eigenelements of Sturm-Liouville problems by using Daubechies wavelets. *Indian Journal of Pure & Applied Mathematics*, doi: 10.1007/S13226-016-0203-6
- Pau, G. (2019). *The Foundations of Iridology: The Eyes as the Key to Your Genetic Health Profile*: Simon and Schuster.
- Peate, I. (2021). The heart: an amazing organ. *British Journal of Healthcare Assistants*, 15(2), 72-77.
- Pencina, M. J., Navar, A. M., Wojdyla, D., Sanchez, R. J., Khan, I., Ellassal, J., . . . Sniderman, A. D. (2019). Quantifying importance of major risk factors for coronary heart disease. *Circulation*, 139(13), 1603-1611.
- Permatasari, L. I., Novianty, A. ve Purboyo, T. W. (2016). *Heart disorder detection based on computerized iridology using support vector machine*. Paper presented at the 2016 International Conference on Control, Electronics, Renewable Energy and Communications (ICCEREC).
- Pradeep, T., Mehra, D. ve Le, P. H. (2019). Histology, Eye.
- Prasatha, V., Alfeilate, H. A. A., Hassanate, A., Lasassmehe, O., Tarawnehf, A. S., Alhasanatg, M. B. ve Salmane, H. S. E. (2017). Effects of distance measure choice on knn classifier performance-a review. *arXiv preprint arXiv:1708.04321*, 56.
- Prof. Dr. Altan Onat, D. D. G. C., Prof. Dr. Hüsnüye Yüksel, Prof. Dr. Evin Ademoğlu, Prof. Dr. Nihan Erginel-Ünaltuna, Doç. Ayşem Kaya, Yard. Doç. Dr. Servet ALTAY. (2017). *TEKHARF 2017 Tıp Dünyasının Kronik Hastalıklara Yaklaşımına Öncülük*. Erişim: <https://file.tkd.org.tr/PDFs/TEKHARF-2017.pdf>

- Putra, L. S. A., Isnanto, R. R., Triwiyatno, A. ve Gunawan, V. A. (2018). *Identification of Heart Disease With Iridology Using Backpropagation Neural Network*. Paper presented at the 2018 2nd Borneo International Conference on Applied Mathematics and Engineering (BICAME).
- Ramzy, I. (2001). *Clinical cytopathology and aspiration biopsy: fundamental principles and practice*: McGraw Hill Professional.
- Rehman, M. U., Najam, S., Khalid, S., Shafique, A., Alqahtani, F., Baothman, F., . . . Ahmad, J. (2021). Infrared sensing based non-invasive initial diagnosis of chronic liver disease using ensemble learning. *IEEE Sensors Journal*, 21(17), 19395-19406.
- Rish, I. (2001). *An empirical study of the naive Bayes classifier*. Paper presented at the IJCAI 2001 workshop on empirical methods in artificial intelligence.
- Room, C. (2019). Confusion Matrix. *Mach. Learn*, 6, 27.
- Samant, P. ve Agarwal, R. (2018). Machine learning techniques for medical diagnosis of diabetes using iris images. *Computer methods and programs in biomedicine*, 157, 121-128.
- Samant, P. ve Agarwal, R. (2019). Analysis of computational techniques for diabetes diagnosis using the combination of iris-based features and physiological parameters. *Neural Computing and Applications*, 31, 8441-8453.
- Sanchis-Gomar, F., Perez-Quilis, C., Leischik, R. ve Lucia, A. (2016). Epidemiology of coronary heart disease and acute coronary syndrome. *Annals of translational medicine*, 4(13).
- Sathyapriya, B., Sumathy, G., Sneha, P. ve Priya, L. J. (2020). Iridology-A Review. *European Journal of Molecular & Clinical Medicine*, 7(3), 1668-1674.
- Senior, K. R. (2010). *The eye: the physiology of human perception*: The Rosen Publishing Group, Inc.
- Serdyuk, S., Davtyan, K., Burd, S., Drapkina, O., Boytsov, S., Gusev, E. ve Topchyan, A. (2021). Cardiac arrhythmias and sudden unexpected death in epilepsy: Results of long-term monitoring. *Heart Rhythm*, 18(2), 221-228.
- Sevastyanov, V. (2019). An experimental study of the specific features of laser radiation propagation through the optical system of the human eye and the optic nerve. *Biomedical Engineering*, 52(5), 340-343.
- Shao, E. ve Wong, S. C. (2020). Vitreous and Retina. *Fundamentals in Ophthalmic Practice* (s. 179-194): Springer.
- Sharan, F. (1989). *Iridology: A complete guide to diagnosing through the iris and to related forms of treatment*: HarperThorsons.
- Shetty, B. ve Pavan, R. (2021). Inclusiveness: Neuroscience Behavior in Teaching and Learning. *Neuro-Systemic Applications in Learning* (s. 71-93): Springer.
- Simon, A., Worthen, D. M. ve Mitas, J. A. (1979). An evaluation of iridology. *Jama*, 242(13), 1385-1389.
- Singh, S. ve Gupta, P. (2014). Comparative study ID3, cart and C4. 5 decision tree algorithm: a survey. *International Journal of Advanced Information Science and Technology (IJAIST)*, 27(27), 97-103.

- Sirico, F., Fernando, F., Di Paolo, F., Adami, P. E., Signorello, M. G., Sannino, G., . . . Filippi, N. (2019). Exercise stress test in apparently healthy individuals– where to place the finish line? The Ferrari corporate wellness programme experience. *European Journal of Preventive Cardiology*, 26(7), 731-738.
- Soh, L.-K. ve Tsatsoulis, C. (1999). Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. *IEEE Transactions on geoscience and remote sensing*, 37(2), 780-795.
- Sruthi, K., Vijayakumar, J. ve Thavamani, S. (2022). Deep Learning-Based Verification of Iridology in Diagnosing Type II Diabetes Mellitus. *International Journal of Pattern Recognition and Artificial Intelligence*, 36(11), 2252017.
- Steinwart, I. ve Christmann, A. (2008). *Support vector machines*: Springer Science & Business Media.
- Sumathy, G. (2020). Iridology-A Review. *European Journal of Molecular & Clinical Medicine*, 7(03), 2020.
- Suthaharan, S. ve Suthaharan, S. (2016). Support vector machine. *Machine learning models and algorithms for big data classification: thinking with examples for effective learning*, 207-235.
- Szewczyk, R., Jablonski, P., Kulesza, Z., Napieralski, A., Cabestany, J. ve Moreno, M. (2002). *Automatic people identification on the basis of iris pattern-extraction features and classification*. Paper presented at the Microelectronics, 2002. MIEL 2002. 23rd International Conference on.
- Tangirala, S. (2020). Evaluating the impact of GINI index and information gain on classification using decision tree classifier algorithm. *International Journal of Advanced Computer Science and Applications*, 11(2), 612-619.
- Tetik, S. S. ve Tanrıverdi, B. (2017). Aterosklerozun patofizyolojisi ve risk faktörleri. *Marmara Pharmaceutical Journal*, 21(1), 1-9.
- Topol, E. J. ve Teirstein, P. S. (2015). *Textbook of interventional cardiology E-Book*: Elsevier Health Sciences.
- TÜİK. (2019). Ölüm ve Ölüm Nedeni İstatistikleri, 2019. Erişim adresi Ölüm ve Ölüm Nedeni İstatistikleri, 2019
- Virani, S. S., Alonso, A., Benjamin, E. J., Bittencourt, M. S., Callaway, C. W., Carson, A. P., . . . Delling, F. N. (2020). Heart disease and stroke statistics—2020 update: a report from the American Heart Association. *Circulation*, 141(9), e139-e596.
- Voigt, A. P., Mullin, N. K., Whitmore, S. S., DeLuca, A. P., Burnight, E. R., Liu, X., . . . Mullins, R. F. (2021). Human photoreceptor cells from different macular subregions have distinct transcriptional profiles. *Human Molecular Genetics*.
- Vresdian, D. J., Hapsari, A. A., Al-Yousif, S., Jaenul, A., Islami, A. Y. ve Dionova, B. W. (2022). *A Review of Image Processing Approaches of the Iridology as A Biomedical*. Paper presented at the 2022 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE).
- Wang, Y. X., Panda-Jonas, S. ve Jonas, J. B. (2020). Optic nerve head anatomy in myopia and glaucoma, including parapapillary zones alpha, beta, gamma and delta: histology and clinical features. *Progress in Retinal and Eye Research*, 100933.

- Webb, G. I., Keogh, E. ve Miikkulainen, R. (2010). Naïve Bayes. *Encyclopedia of machine learning*, 15, 713-714.
- Weinhaus, A. J. ve Roberts, K. P. (2005). Anatomy of the human heart. *Handbook of cardiac anatomy, physiology, and devices*, 51-79.
- Weston, J. ve Watkins, C. (1998). *Multi-class support vector machines*. Erişim:
- Wexler, R., Elton, T., Pleister, A. ve Feldman, D. (2009). Cardiomyopathy: an overview. *American family physician*, 79(9), 778.
- WHO, W. H. O. (2021). Cardiovascular diseases (CVDs). Erişim adresi [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (Erişim tarihi: 01.09.2022)
- Williams, A. R. ve Hare, J. M. (2011). Mesenchymal stem cells: biology, pathophysiology, translational findings, and therapeutic implications for cardiac disease. *Circulation research*, 109(8), 923-940.
- Williams, K., Carson, J. ve Lo, C. (2019). Genetics of congenital heart disease. *Biomolecules*, 9(12), 879.
- Wilson, P. W., D'Agostino, R. B., Sullivan, L., Parise, H. ve Kannel, W. B. (2002). Overweight and obesity as determinants of cardiovascular risk: the Framingham experience. *Archives of internal medicine*, 162(16), 1867-1872.
- Wilson, S. E. (2020). Corneal wound healing. *Experimental eye research*, 197, 108089.
- Yadav, I., Purohit, S. D., Singh, H., Das, N., Roy, P. ve Mishra, N. C. (2021). A highly transparent tri-polymer complex in situ hydrogel of HA, collagen and four-arm-PEG as potential vitreous substitute. *Biomedical Materials*, 16(6), 065018.
- Yegnanarayana, B. (2009). *Artificial neural networks*: PHI Learning Pvt. Ltd.
- Yılmazel, G. ve Ahcıoğlu, A. (2021). Halk sağlığı gözüyle koroner arter hastalığı ve sağlık okuryazarlığı. *Turkey Health Literacy Journal*, 2(2), 81-88.
- Yohannes, C., Nurtanio, I. ve Halim, K. C. (2020). Potential of Heart Disease Detection Based on Iridology. *IOP Conference Series: Materials Science and Engineering*, 875, 012034. doi:10.1088/1757-899x/875/1/012034
- Yu, D.-Y., Cringle, S. J., Paula, K. Y. ve Su, E.-N. (2020). Anatomy and Histology of the Macula. *Macular Surgery* (s. 3-14): Springer.
- Yusuf, S., Hawken, S., Ôunpuu, S., Dans, T., Avezum, A., Lanas, F., . . . Varigos, J. (2004). Effect of potentially modifiable risk factors associated with myocardial infarction in 52 countries (the INTERHEART study): case-control study. *The lancet*, 364(9438), 937-952.
- Zaeni, A., Kasnalestari, T. ve Khayam, U. (2018). Application of Wavelet Transformation Symlet Type and Coiflet Type For Partial Discharge Signals Denoising. *2018 5th International Conference on Electric Vehicular Technology (ICEVT)*, Surakarta, Indonesia, pp. 78-82, doi: 10.1109/ICEVT.2018.8628460.
- Zaloğlu, O. (2015). Dünyayı Değiştirmekte Olan Yapay Sinir Ağları Nedir? Erişim adresi <https://bilimfili.com/dunyayi-degistirmekte-olan-yapay-sinir-aglari-nedir> (Erişim tarihi: 01.09.2022)

Zhang, L., Wang, B., Zhou, J., Kirkpatrick, J., Xie, M. ve Johri, A. M. (2020). Bedside focused cardiac ultrasound in COVID-19 from the Wuhan epicenter: the role of cardiac point-of-care ultrasound, limited transthoracic echocardiography, and critical care echocardiography. *Journal of the American Society of Echocardiography*, 33(6), 676-682.

Zheng, L., Shi, H. ve Sun, S. (2016). *Underwater image enhancement algorithm based on CLAHE and USM*. Paper presented at the 2016 IEEE International Conference on Information and Automation (ICIA).



EKLER

Etik Kurul Kararı

KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU

ARAŞTIRMANIN AÇIK ADI		İskemik Kalp Hastalarının İris Analizi Yöntemi ile Belirlenmesi		
VARSA ARAŞTIRMANIN PROTOKOL KODU		SÖKA EK-2022/12/21		
DEĞERLENDİRİLEN BELGELER	Belge Adı	Tarihi	Versiyon Numarası	Dili
	ARAŞTIRMA PROTOKOLÜ	16.11.2022	0.2	Türkçe ☒ İngilizce ☐ Diğer ☐
	BİLGİLENDİRİLMİŞ GÖNÜLLÜ OLUR FORMU	16.11.2022	0.2	Türkçe ☒ İngilizce ☐ Diğer ☐
	OLGU RAPOR FORMU			Türkçe ☐ İngilizce ☐ Diğer ☐
	ARAŞTIRMA BROŞÜRÜ			Türkçe ☐ İngilizce ☐ Diğer ☐
DEĞERLENDİRİLEN DİĞER BELGELER	Belge Adı	Açıklama		
	SİGORTA	☐		
	ARAŞTIRMA BÜTÇESİ	☐		
	BIYOLOJİK MATERİYEL TRANSFER FORMU	☐		
	İLAN	☐		
	YILLIK BİLDİRİM	☐		
	SONUÇ RAPORU	☐		
	GÜVENLİLİK BİLDİRİMLERİ	☐		
	DİĞER:	☐		
KARAR BİLGİLERİ	Karar No:2022/12/21	Tarih: 23/11/2022		
	Yukarıda bilgileri verilen başvuru dosyası ile ilgili belgeler araştırmanın/çalışmanın gerekece, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup araştırmanın/çalışmanın başvuru dosyasında belirtilen merkezlerde gerçekleştirilmesinde etik ve bilimsel sakınca bulunmadığına toplantıya katılan etik kurul üye tam sayısının salt çoğunluğu ile karar verilmiştir. İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik kapsamında yer alan araştırmalar/çalışmalar için Türkiye İlaç ve Tıbbi Cihaz Kurumu'ndan izin alınması gerekmektedir.			

KLİNİK ARAŞTIRMALAR ETİK KURULU	
ETİK KURULUN ÇALIŞMA ESASI	İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu
BAŞKANIN UNVANI / ADI / SOYADI:	Prof. Dr. Özgür GÜNAL

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet	Araştırma ile İlişki	Katılım *	İmza ²
Prof. Dr. Özgür GÜNAL (Başkan)	Enfeksiyon Hast. ve Klinik Mikrobiyolojisi	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Doç. Dr. Mahir ÇUBUKÇU (Başkan Yardımcısı)	Aile Hekimliği	Samsun Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☐ H ☐	
Doç. Dr. Doğan ÖZDEMİR	Kulak Burun Boğaz H.	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Doç. Dr. Yener KÖKSAL	Beyin ve Sinir Cerrahisi	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Doç. Dr. Mehmet KÖÇÜK	Çocuk Kardiyolojisi	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Doç. Dr. Semra EROĞLU	Kadın Hast. Ve Doğum	Samsun Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☐ H ☐	
Doç. Dr. Emin DALDAL	Genel Cerrahi	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Dr. Öğr. Üyesi Aysa ÇEÇEN	Kulak Burun Boğaz H.	Samsun Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☐ H ☐	
Dr. Öğr. Üyesi Şule ÖZDEMİR	Halk Sağlığı	Samsun Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☐ H ☐	
Dr. Öğr. Üyesi Ömer BOZDUMAN	Ortopedi ve Travm.	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Dr. Öğr. Üyesi Caner GÜNAYDIN	Tıbbi Farmakoloji	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Uzm. Dr. Melek BİLİGİN	Tıbbi Mikrobiyoloji	Samsun Eğitim ve Araştırma Hast.	E ☐ K ☒	E ☐ H ☒	E ☐ H ☐	
Avukat Sedat KAYA	Avukat	Samsun Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Mühendis Caner Ali ASLAN	Mühendis	Samsun Eğitim ve Araştırma Hast.	E ☒ K ☐	E ☐ H ☒	E ☐ H ☐	
Öğretmen Benal EROL	Sınıf Öğretmeni	Millî Eğitim Bakanlığı	E ☐ K ☒	E ☐ H ☒	E ☐ H ☐	

Etik Kurul Başkanının
Unvanı/Adı/Soyadı: Prof. Dr. Özgür GÜNAL
İmza:

ASLI GİBİDİR

**Etik Kurul
Nesrin YURDAKÖŞ
T8871**

Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmıştır.

ÖZ GEÇMİŞ

Ferdi ÖZBİLGİN, Tokat Gaziosmanpaşa Lisesi’ni bitirdikten sonra Cumhuriyet Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü’nden 2014 yılında mezun oldu. 2019 yılında OMÜ FBE Elektrik-Elektronik Mühendisliği Anabilim dalı Yüksek Lisans programını bitirdi. 2016 yılından bu yana Giresun Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü’nde araştırma görevlisi olarak görev yapan Ferdi ÖZBİLGİN, iyi derecede İngilizce bilmektedir. Temel ilgi alanları, Görüntü İşleme, Sinyal İşleme ve Makine Öğrenmesidir. (19.09.2023).

İletişim Bilgileri

Öğrenci no : 19211620
ORCID ID : 0000-0003-4946-7018

Yayınlar:

- Özbilgin, F. ve Kurnaz, Ç.** (2022). An alternative approach for determining the cholesterol level: Iris analysis. International Journal of Imaging Systems and Technology, 32(4), 1159-1171, DOI:10.1002/ima.22689
- Özbilgin, F., Kurnaz, Ç. ve Aydın, E.** (2023). Prediction of Coronary Artery Disease Using Machine Learning Techniques with Iris Analysis. Diagnostics, 13(6), 1081, DOI:10.3390/diagnostics13061081
- Özbilgin, F. ve Kurnaz, Ç.** (2023). Koroner Arter Hastalığının İris Görüntülerinden Yerel İkili Örüntüler ve Yapay Sinir Ağı Kullanılarak Tahmini. Karedeniz Fen Bilimleri Dergisi, 13(2), 665-679, DOI:10.31466/kfbd.1266996