

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI**

**TIBBİ GÖRÜNTÜLERDEN DERİN ÖĞRENME TABANLI
HASTALIK TEŞHİSİ İÇİN ÖZNİTELİK ÇIKARMA,
SIRALAMA VE SEÇME YÖNTEMLERİNE DAYALI YENİ
BİR KARAR DESTEK SİSTEMİ**

**Hazırlayan
Tuğba Nur BOZKURT**

**Danışman
Prof. Dr. Mehmet Emin YÜKSEL**

Yüksek Lisans Tezi

**Temmuz 2024
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI**

**TIBBİ GÖRÜNTÜLERDEN DERİN ÖĞRENME TABANLI
HASTALIK TEŞHİSİ İÇİN ÖZNİTELİK ÇIKARMA,
SIRALAMA VE SEÇME YÖNTEMLERİNE DAYALI YENİ
BİR KARAR DESTEK SİSTEMİ
(Yüksek Lisans Tezi)**

**Hazırlayan
Tuğba Nur BOZKURT**

**Danışman
Prof. Dr. Mehmet Emin YÜKSEL**

**Bu çalışma, Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi
tarafından FYL-2023-12819 kodlu proje ile desteklenmiştir.**

**Temmuz 2024
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Tuğba Nur BOZKURT

İmza

“Tıbbi Görüntülerden Derin Öğrenme Tabanlı Hastalık Teşhisi için Öznitelik Çıkarma, Sıralama ve Seçme Yöntemlerine Dayalı Yeni Bir Karar Destek Sistemi”
adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan

Tuğba Nur BOZKURT

İmza

Danışman

Prof. Dr. Mehmet Emin YÜKSEL

İmza

Biyomedikal Mühendisliği ABD Başkanı

Prof. Dr. Semra İÇER

İmza

TEŞEKKÜR

Bu tezin hazırlanması sürecinde desteklerini esirgemeyen birçok değerli insanın katkıları olmuştur.

Öncelikle tez danışmanım, saygı değer hocam Prof. Dr. Mehmet Emin Yüksel'e rehberliği, sabrı ve teşvik edici yaklaşımı için sonsuz teşekkürlerimi sunarım. Onun değerli önerileri ve yapıcı eleştirileri çalışmamın her aşamasında yol gösterici olmuştur.

Ek olarak saygı değer hocam Doç. Dr. Gökhan Ertaş'a bu çalışmadaki istatistiksel sonuçların elde edilmesindeki katkılarından dolayı teşekkürlerimi sunarım.

Ayrıca çalışmalarım süresince bana her türlü yardımı ve fedakârlığı sağlayan sevgili aileme teşekkür ederim. Özellikle, moral desteği sağlayarak ve bana sabır göstererek bu süreci daha kolay hale getiren sevgili annem Fatma Sevgi Bozkurt'a ve babam Mehmet Bozkurt'a minnettarım.

Arkadaşlarım Fatime Oumar Djibrillah ve Tefrika Turan'a çalışmalarımız sırasında benimle yaptıkları bilgi paylaşımı için ve çalışmalarımızı yürütürken beraber geçirdiğimiz kıymetli ve verimli zamanlar için çok teşekkür ederim.

Tuğba Nur BOZKURT

Temmuz 2024, KAYSERİ

TIBBİ GÖRÜNTÜLERDEN DERİN ÖĞRENME TABANLI HASTALIK TEŞHİSİ İÇİN ÖZNİTELİK ÇIKARMA, SIRALAMA VE SEÇME YÖNTEMLERİNE DAYALI YENİ BİR KARAR DESTEK SİSTEMİ

Tuğba Nur BOZKURT

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Temmuz 2024
Danışman: Prof. Dr. Mehmet Emin YÜKSEL**

ÖZET

Dünya genelindeki doktor sayısının yetersizliği; doktorların iş yükünü oldukça arttırırken, hastalarında doğru, vaktinde ve erişilebilir maliyette sağlık hizmeti almasını engellemektedir. Bu yüzden doktorların iş yükünü azaltacak, hastaların doğru ve vaktinde sağlık hizmeti almasını sağlayacak bir sistem geliştirilmesi oldukça önemlidir. Bu çalışmada tıbbi görüntülerle teşhis edilebilen hastalıkların hızlı ve etkin bir şekilde teşhis edilmesini sağlayan yeni bir yöntem önerilmektedir. Önerilen yöntem, AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağları ile öznitelik çıkarma, iki örneklemlili z-test yöntemiyle öznitelik sıralama ve ikili genetik algoritma (BGA) yöntemiyle öznitelik seçme yöntemlerinin kombine bir şekilde kullanılması yoluyla tıbbi görüntülerin çok az sayıda öznitelikle, hızlı ve yüksek doğrulukla sınıflandırılmasını sağlayan ve bu yolla düşük maliyetli donanımlar üzerinde gerçekleştirilebilen bir karar destek sistemi yöntemidir. Yöntemin performansı 3 farklı veri seti üzerinde, 4-katlı çapraz doğrulama ile k-En Yakın Komşu (KNN) ve Destek Vektör Makineleri (SVM) sınıflandırıcıları kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, önerilen yöntemin tıbbi görüntülerin çok az öznitelikle hızlı ve yüksek doğrulukla sınıflandırılmasında etkin rol oynadığını göstermiştir.

Anahtar Kelimeler: Tıbbi görüntüler, AlexNet, ResNet-101, Öznitelik vektörü çıkarma, Öznitelik sıralama, Öznitelik seçme, Makineli öğrenme, Sınıflandırma, Karar destek sistemi.

**A NEW DECISION SUPPORT SYSTEM BASED ON FEATURE
EXTRACTION, RANKING AND SELECTION METHODS FOR DEEP
LEARNING-BASED DISEASE DIAGNOSIS FROM MEDICAL IMAGES**

Tuğba Nur BOZKURT

Erciyes University, Graduate School of Natural and Applied Sciences

Master Thesis, July 2024

Supervisor: Prof. Dr. Mehmet Emin YÜKSEL

ABSTRACT

The continuing shortage of medical professionals around the world steadily escalates their workload while hindering patients from accessing suitable, timely, and cost-effective health services. Therefore, it becomes increasingly crucial to develop appropriate decision support systems that will alleviate the workload of medical professionals while ensuring that patients receive suitable and timely health services. This study introduces a novel method for the rapid and accurate diagnosis of diseases using medical images acquired through various medical imaging techniques. The proposed approach is based on the combined use of feature extraction using AlexNet, ResNet-101, AlexNet + ResNet-101 neural networks, feature ranking with two-sample z-test, and feature selection with binary genetic algorithm. From this respect, the proposed approach is an innovative decision support system that provides rapid and accurate classification of medical images using much fewer features and can be deployed on low-cost hardware. The performance of the proposed method was assessed using three distinct datasets by implementing k-Nearest Neighbors (KNN) and Support Vector Machine (SVM) classifiers with 4-fold cross validation. Obtained results demonstrate that the proposed method is very successful in highly accurate classification of medical images despite utilizing much fewer features leading to significantly lower computational cost.

Keywords: Medical images, AlexNet, ResNet-101, Feature vector extraction, Feature ranking, Feature selection, Machine learning, Classification, Decision support system.

İÇİNDEKİLER

TIBBİ GÖRÜNTÜLERDEN DERİN ÖĞRENME TABANLI HASTALIK TEŞHİSİ İÇİN ÖZNİTELİK ÇIKARMA, SIRALAMA VE SEÇME YÖNTEMLERİNE DAYALI YENİ BİR KARAR DESTEK SİSTEMİ

BİLİMSEL ETİĞE UYGUNLUK	ii
YÖNERGEYE UYGUNLUK.....	iii
KABUL VE ONAY	iv
TEŞEKKÜR.....	v
ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	xi
TABLolar LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ	xv
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR TARAMASI

1.1. Tıbbi Görüntüler ve Analizi.....	3
1.2. Literatür Taraması	6
1.3. Problemin Durumu	12
1.4. Araştırmanın Amacı	13
1.5. Araştırmanın Önemi.....	13

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Veri Setleri.....	16
2.2. Öznitelik Çıkarma.....	17
2.2.1. Evrişimsel Sinir Ağları ile Öznitelik Çıkarma	18

2.2.1.1. AlexNet Ağı ile Öznitelik Çıkarma	24
2.2.1.2. ResNet-101 ile Öznitelik Çıkarma	24
2.2.1.3. Öznitelik Birleştirme.....	25
2.3. Öznitelik Sıralama	26
2.3.1. İki Örneklemli z-Test Yöntemi ile Öznitelik Sıralama.....	28
2.4. Öznitelik Seçme	29
2.4.1. Genetik Algoritma	30
2.4.1.1. Genetik Algoritmanın Uygulama Aşamaları.....	32
2.4.1.1.1 Seçim	34
2.4.1.1.2 Çaprazlama.....	37
2.4.1.1.3 Mutasyon.....	40
2.4.1.1.4 Elitizm (Seçkinlik).....	41
2.4.2. Binary Genetik Algoritma ile Öznitelik Seçme.....	42
2.5. Sınıflandırma.....	46
2.5.1. Doğrulama Teknikleri	46
2.5.1.1. Test Seti Yöntemi (Holdout).....	46
2.5.1.2. LOOCV yöntemi (Leave-One-Out Cross Validation)	46
2.5.1.3. N-Katlı Çapraz Doğrulama (N-Fold Cross Validation)	47
2.5.2. Makineli Öğrenme Yöntemleri ile Sınıflandırma	48
2.5.2.1. K-En Yakın Komşu Algoritması (K-Nearest Neighbor - KNN)	49
2.5.2.2. Destek Vektör Makineleri Algoritması (Support Vector Machine - SVM)	51
2.5.3 Performans Metrikleri	53
2.6. İstatistiksel Analiz.....	56

3. BÖLÜM

DENEYSEL SONUÇLAR

3.1 Giriş.....	58
----------------	----

3.2 Deneysel Sonuçlar	58
-----------------------------	----

3.3. İstatistiksel Anlamlılık Sonuçları	67
---	----

4. BÖLÜM

SONUÇ TARTIŞMA ve ÖNERİLER

4.1. Sonuç	74
------------------	----

4.2.Tartışma	75
--------------------	----

4.3. Öneriler	76
---------------------	----

KAYNAKÇA	77
----------------	----

ÖZGEÇMİŞ.....	83
---------------	----

KISALTMALAR

BGA	: Binary Genetik Algoritma
KNN	: K-En Yakın Komşu
SVM	: Destek Vektör Makinesi
CNN	: Evrimsel Sinir Ağı
WHO	: Dünya Sağlık Örgütü
CAD	: Bilgisayar Destekli Tespit veya Teşhis
DCT	: Ayrık Kosinüs Dönüşümü
SFS	: Stokastik Fraktal Arama
WOA	: Kılavuzlu Balina Optimizasyon Algoritması
NN	: Sinir Ağı
DT	: Karar Ağacı
PSO	: Parçacık Sürü Optimizasyonu
MR	: Manyetik Rezonans
PET	: Pozitron Emisyon Tomografisi
SPECT	: Tek Foton Emisyon Bilgisayarlı Tomografi
AUC	: Eğri Altında Kalan Alan
AAPSO	: Adaptif ve Atıstik Parçacık Sürüsü Optimizasyonu
INCA	: Yinelemeli Komşuluk Bileşen Analizi
IRF	: Yinelemeli Relief
ECNCA	: Entropi Kontrollü Komşuluk Bileşen Analizi

BGWO	: Binary Gri Kurt Optimizasyon Algoritması
BT	: Bilgisayarlı Tomografi
ACM	: Aktif Kontur Modeli
ABC	: Yapay Arı Kolonisi
IDRiD	: Hint Diyabetik Retinopati Görüntü Veri Kümesi
ADNI	: Alzheimer Hastalığı Nörogörüntüleme Girişimi
GPU	: Grafik İşlem Birimi
ISIC	: Uluslararası Cilt Görüntüleme İşbirliği
ReLU	: Rektifiye Lineer Birim
RFE	: Özyinelemeli Özelliğin Ortadan Kaldırılması
LOOCV	: Birini Dışarıda Bırakma Çapraz Doğrulaması
LR	: Doğrusal Regresyon
DP	: Doğru Pozitif
DN	: Doğru Negatif
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
CLT	: Merkezi Limit Teoremi
MCI	: Hafif Bilişsel Bozukluk

TABLOLAR LİSTESİ

Tablo 2.1. Aktivasyon fonksiyonlarının denklemleri ve grafikleri.....	23
Tablo 2.2. Her yöntemin veri setlerine tek tek uygulanmasından sonra elde edilen öznitelik sayıları	26
Tablo 2.3. Öznitelik seçme yöntemleri ve bu yöntemlerin yaklaşımları	27
Tablo 2.4. Kromozomlar ve uygunluk değerleri	34
Tablo 2.5. Kromozomlar ve normalize edilmiş uygunluk değerleri	35
Tablo 2.6. Mesafe hesaplama yöntemleri ve formülleri	50
Tablo 2.7 Örnek bir karışıklık matrisi.....	53
Tablo 3.1. Veriseti-1 için sinir ağlarından elde edilen öznitelik vektörlerinin sınıflandırma sonuçları.....	59
Tablo 3.2. Veriseti-2 için sinir ağlarından elde edilen öznitelik vektörlerinin sınıflandırma sonuçları.....	60
Tablo 3.3. Veriseti-3 için sinir ağlarından elde edilen öznitelik vektörlerinin sınıflandırma sonuçları.....	60
Tablo 3.4. Veriseti-1 için iki örneklemlerle z-testi yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	61
Tablo 3.5. Veriseti-2 için iki örneklemlerle z-testi yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	62
Tablo 3.6. Veriseti-3 için iki örneklemlerle z-testi yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	62
Tablo 3.7. Veriseti-1 için binary genetik algoritma yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	63

Tablo 3.8. Veriseti-2 için binary genetik algoritma yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	64
Tablo 3.9. Veriseti-3 için binary genetik algoritma yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	64
Tablo 3.10 Veriseti-1 için sadece öznitelik çıkarma ve öznitelik seçme işlemleri kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	66
Tablo 3.11 Veriseti-2 için sadece öznitelik çıkarma ve öznitelik seçme işlemleri kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	66
Tablo 3.12 Veriseti-3 için sadece öznitelik çıkarma ve öznitelik seçme işlemleri kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları	67
Tablo 3.13. KNN algoritması ile gerçekleştirilen deneylerle ilgili veri setleri için sinir ağlarına ait normallik testi sonuçları	69
Tablo 3.14. KNN algoritması ile gerçekleştirilen deneylerde sinir ağları için elde edilen Kruskal-Wallis test sonuçları.	69
Tablo 3.15. KNN algoritması ile gerçekleştirilen deneylerde sinir ağları için elde edilen Mann-Whitney U test sonuçları	70
Tablo 3.16. SVM algoritması ile gerçekleştirilen deneylerde ilgili veri setleri için sinir ağlarına ait normallik testi sonuçları	71
Tablo 3.17. SVM algoritması ile gerçekleştirilen deneylerde sinir ağları için elde edilen Kruskal-Wallis test sonuçları	72
Tablo 3.18. SVM algoritması ile gerçekleştirilen deneylerde sinir ağları için elde edilen Mann-Whitney U test sonuçları	72

ŞEKİLLER LİSTESİ

Şekil 1.1. X-ışınlarının üretilmesi	4
Şekil 2.1. Sunulan yaklaşımın akış şeması	16
Şekil 2.2. Bu çalışmada kullanılan veri setlerine ait örnek görüntüler	17
Şekil 2.3. Bir CNN modelinin genel yapısı.....	18
Şekil 2.4. Konvolüsyon işlemi	20
Şekil 2.5. Maksimum indirgeme işlemi	21
Şekil 2.6. Ortalama indirgeme işlemi.....	21
Şekil 2.7. Düzleştirme işlemi	22
Şekil 2.8. Gen, Kromozom ve Popülasyon	32
Şekil 2.9. Genetik algoritmanın akış şeması	33
Şekil 2.10. Rulet Tekerleği.....	36
Şekil 2.11. Tek noktalı çaprazlama	39
Şekil 2.12. Çok noktalı çaprazlama.....	40
Şekil 2.13. Düzgün Çaprazlama.....	40
Şekil 2.14. Başlangıç popülasyonu	43
Şekil 2.15. 4-Katlı çapraz doğrulama işlemi	47
Şekil 2.16. KNN algoritmasının sınıflandırma mekanizması	51
Şekil 2.17. Hiper düzlemin oluşturulması.....	52

GİRİŞ

Tıbbi görüntüler canlıların vücut yapılarını ve bu yapıların fonksiyonlarını incelemek için kullanılan görsel verilerdir. Tıbbi görüntülerin uygun şekilde incelenmesi hastalıkların doğru bir şekilde teşhis edilmesi, etkili tedavi planının oluşturulması ve uygulanan tedavinin etkinliğinin takip edilmesi için oldukça önemlidir. Bu yüzden bu görüntülerin analizi ve yorumlanması anatomik ve teknik bilgiye sahip, klinik bulgular ve semptomlar hakkında bilgi sahibi bir uzman tarafından gerçekleştirilmelidir. Ancak dünya genelindeki uzman sayısı hızla artan hasta sayıları karşısında yetersiz kalmaktadır. Bu durum özellikle görüntüleme yöntemleri kullanılarak teşhis edilebilen hastalıkların tanı ve tedavisinde gecikmelere neden olmaktadır. Bu yüzden bilim insanları uzman eksikliğinden kaynaklanan bu sorunların üstesinden gelmek ve uzmanların iş yükünü hafifletmek için yeni çözüm yolları arayışına girişmiştir.

Bilgisayar teknolojilerindeki gelişmeler ve yapay zeka alanındaki ilerlemeler görüntü ve sinyallerin yapay zeka tabanlı yaklaşımlarla analiz edilmesini ve bu sayede hastalıkların doğru bir şekilde teşhis edilebilmesini kolaylaştırmıştır. Özellikle evrimsel sinir ağlarının (Convolutional Neural Networks - CNN) geliştirilmesi görüntü verilerinin etkin analizini kolaylaştırarak yapay zekanın uygulama alanını genişletmiştir. Bu gelişmeler ile birlikte literatürde tıbbi görüntü verilerini analiz edip sınıflandırarak hastalıkları teşhis edebilen, uzmanların ve radyologların iş yükünü azaltan, yapay zekâ tabanlı pek çok çalışma gerçekleştirilmiştir. Ancak CNN ve benzeri yapay zeka yaklaşımlarının parametre sayısının fazlalığı sebebiyle oluşan işlemsel yük çok fazladır. Bu sebeple bu türden modellerin gerçekleşmesi için ihtiyaç duyulan fiziksel donanımların işlem kapasitelerinin oldukça yüksek olması gerekmektedir. Bu durum CNN ve benzeri yapay zeka yaklaşımlarının yaygınlaşmasını büyük ölçüde etkilemektedir. Bu yüzden bu çalışmada CNN modelleri eğitilmeden sadece CNN'ler tarafından üretilen tıbbi görüntülere ait öznitelik vektörlerini kullanan bir yöntem sunulmuştur. Bu yöntemde

CNN'lerden elde edilen öznitelik vektörlerine öznitelik sıralama ve öznitelik seçme işlemleri uygulanarak tıbbi görüntülerin çok az öznitelikle temsil edilmesi sağlanmıştır. Tıbbi görüntüleri temsil eden bu öznitelikler işlemsel karmaşıklığı oldukça düşük makineli öğrenme yöntemleri ile sınıflandırılmıştır. Bu yolla tıbbi görüntülerin işlemsel yükü oldukça az bir yaklaşımla sınıflandırılmasını sağlayan, düşük maliyetli donanımlar üzerinde gerçekleştirilecek bir yöntem sunulmuştur. Sunulan yöntemle ilgili detaylar ilerleyen bölümlerde açıklanmıştır.




1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR TARAMASI

1.1. Tıbbi Görüntüler ve Analizi

Tıbbi görüntüler, insan vücudunun anatomisinde meydana gelen değişikliklerin ve işleyişindeki aksaklıkların boyutunu incelemek amacıyla kullanılan görsel verilerdir. Bu görüntüler hastalıkların teşhis edilmesi, tedavi planının belirlenmesi, uygulanan tedavinin etkinliğinin izlenmesi için sıklıkla kullanılır. Vücutta incelemesi amaçlanan dokuya ve fonksiyona göre geliştirilmiş pek çok görüntüleme tekniği mevcuttur. Tıpta en sık kullanılan görüntüleme teknikleri ve kullanım alanları aşağıda açıklanmıştır [1].

- **Röntgen (X-Ray Imaging):** Röntgen x-ışınları kullanılarak yapılan bir görüntüleme ve teşhis yöntemidir. X-ışınları, bir tüp içerisinde bulunan katottan çıkan elektronların anoda hızla çaptırılması sonucu oluşan yüksek enerjili ışınlardır. Şekil 1.1 de görüldüğü gibi katotta bulunan flaman gerilim verilerek 2200 °C 'ye kadar ısıtılır. Isı 2200 °C'yi geçtikten sonra tungsten atomunun en dış yörüngesinde bulunan elektronlar serbest hale geçer. Serbest hale geçen elektronlar anotta bulunan tungsten hedefe hızla çaptırılır. Böylelikle anotta bulunan tungsten atomuna ait elektronlar katottan gelen elektronların çarpması ile saçılır. Saçılan bu ışınlar x-ışınları denir. Üretilen bu x-ışınları kullanarak kemik kırıkları, diş sorunları, akciğer rahatsızlıkları, tümörler, enfeksiyonlar ve diğer patolojik durumların görüntülenmesi sağlanır.



Şekil 1.1. X-ışınlarının üretilmesi

- **Ultrasonografi (Ultrason):** Ultrason görüntüsünde darbe-yansıma (pulse-echo) prensibinden faydalanılarak görüntü üretilir. Yüksek frekansta ses dalgaları ultrason cihazının probundan (transducer) gönderilir. Gönderilen ses dalgaları çarptıkları dokunun sertliğine ve kütle yoğunluğuna bağlı olarak hızları değişmiş bir şekilde geri döner. Dönen bu ses dalgaları aynı probdan faydalanılarak toplanır. Toplanan bu ses dalgaları işlenerek yumuşak dokuların görüntüleri üretilir. Üretilen bu görüntüler yardımıyla uzmanlar karaciğer, böbrek, kalp, rahim, yumurtalık, tümör ve kist incelemeleri, hamilelik takibi gibi birçok uygulama gerçekleştirebilir.
- **Bilgisayarlı Tomografi (CT):** X-ışınları kullanarak organların, kemiklerin, damarların, tümörlerin ayrıntılı kesitsel görüntülerinin elde edilmesini sağlayan tekniktir.
- **Manyetik Rezonans (MR):** Manyetik alanlardan faydalanarak yüksek çözünürlükte anatomik ve fonksiyonel görüntülerin elde edilmesini sağlayan

tekniktir. Genellikle yumuşak dokuların, organların, damarların, tümörlerin ve sinir sisteminin görüntülenmesi amacıyla kullanılır.

- **Pozitron Emisyon Tomografisi (PET):** Radyoaktif izotoplarla işaretlenmiş bileşiklerin vücuttaki dağılımının ölçülmesi ile gerçekleştirilen görüntüleme tekniğidir. Metabolizma ve kanser lezyonlarının izlenmesi gibi fonksiyonel bilgilerin elde edilmesini sağlar.
- **Tek Foton Emisyon Bilgisayarlı Tomografi (SPECT):** Radyoaktif izotoplarla işaretlenmiş bileşiklerin vücutta izlediği yolların ve akış miktarının ölçülmesi ile gerçekleştirilen görüntüleme tekniğidir. Sıklıkla organların fonksiyonlarının takibi, dolaşım sistemi incelemeleri ve kemik taramaları için kullanılır.
- **Endoskopi:** Küçük boyuttaki bir kamera ile iç organları doğrudan görmek için kullanılan bir tekniktir. Mide, ince bağırsak, kalın bağırsak, yemek borusu, soluk borusu, burun gibi organların incelenmesinde kullanılır.
- **Mamografi:** Meme dokusundaki anomalilerin incelenmesi için kullanılan röntgen tabanlı bir görüntüleme tekniğidir. Özellikle meme kanseri taramasında sıklıkla kullanılır.
- **Mikroskopi:** Hücre düzeyinde inceleme yapmak için kullanılan görüntüleme tekniğidir. Özellikle patoloji ve kanser teşhisi gibi uygulamalarda sıklıkla kullanılır.

Bu görüntüleme tekniklerine ek olarak, her geçen gün hastalıklara daha kesin tanı koymak ve tedavi planını detaylandırmak için kızılötesi ışın, ultraviyole ışık, mor ötesi ışık ve lazer gibi çeşitli yöntemlerden faydalanan yeni görüntüleme teknikleri geliştirilmektedir.

Görüntüleme tekniklerinin çeşitliliği, görüntülenecek dokuların karmaşıklığı sebebiyle tıbbi görüntülerin incelenmesi ve analiz edilmesi oldukça zordur. Tüm bu zorluklara rağmen tıbbi görüntülerin uygun şekilde incelenmesi ve analiz edilmesi, hastalıkların doğru bir şekilde teşhis edilmesi, etkili tedavi planının oluşturulması ve uygulanan tedavinin etkinliğinin takip edilmesi için oldukça önemlidir. Bu yüzden bu görüntülerin analizi ve yorumlanması anatomik ve teknik bilgiye sahip, hastanın özgeçmişi, klinik bulguları ve semptomları hakkında bilgi sahibi bir uzman ya da radyolog tarafından gerçekleştirilmelidir [2].

Son zamanlarda dünya genelindeki kanser, diyabet ve diğer genetik ve kronik hastalıklara yakalanan kişilerin sayısı hızla artarken, uzman sayısı hasta sayısı ile orantılı olarak artmamaktadır. Bu nedenle birçok ülkede hastalar yeterli sağlık hizmetine ulaşamazken, uzmanlarının iş yükü de sürekli artmaktadır [3]. Dünya Sağlık Örgütü'nün (WHO) 2023 yılında yayınladığı "WHO Health Workforce Support and Safeguards List 2023 (WHO Sağlık İşgücü Desteği ve Koruma Önlemleri Listesi 2023) " raporuna göre 55 ülkede uzman eksikliğinden kaynaklanan sıkıntılar yaşanmaktadır. Bu ülkelerde bir sağlık çalışanı başına yaklaşık 200 hasta düşmektedir [4]. Bu durum özellikle görüntüleme yöntemleri kullanılarak teşhis edilebilen hastalıkların tanı ve tedavisinde gecikmelere neden olmakta ve dolayısıyla gelişmemiş ve gelişmekte olan ülkelerde mortalite ve morbidite oranlarında önemli artışlara neden olmaktadır. Bilim insanları uzman eksikliğinden kaynaklanan bu sorunların üstesinden gelmek ve uzmanların iş yükünü hafifletmek için pek çok yeni çözüm yolu geliştirmiştir.

Bilgisayar teknolojilerindeki gelişmeler ve yapay zeka alanındaki ilerlemeler görüntü ve sinyallerin yapay zeka tabanlı yaklaşımlarla analiz edilmesini ve bu sayede hastalıkların hızlı ve doğru bir şekilde teşhis edilebilmesini kolaylaştırmıştır. Özellikle evrimsel sinir ağlarının geliştirilmesi görüntü verilerinin etkin analizini ve sınıflandırılmasını kolaylaştırarak yapay zekanın uygulama alanını oldukça genişletmiştir [5]. Bu gelişmeler ile birlikte literatürde tıbbi görüntü verilerini analiz edip sınıflandırarak hastalıkları teşhis edebilen, uzmanların ve radyologların iş yükünü azaltan, yapay zekâ tabanlı pek çok çalışma gerçekleştirilmiştir [6]. “Literatür Taraması” bölümünde farklı görüntüleme modaliteleri kullanılarak elde edilmiş tıbbi görüntülerin, çeşitli yapay zeka yaklaşımlarından faydalanılarak etkin bir şekilde analiz edilip sınıflandırılmasını sağlamak amacıyla gerçekleştirilmiş güncel çalışmalara değinilmektedir.

1.2. Literatür Taraması

Quing ve arkadaşları [7], yüksek çözünürlüklü bilgisayarlı tomografi görüntülerinden faydalanarak interstisyel akciğer hastalığının örüntülerini teşhis edecek bir CNN ağı geliştirmeyi amaçlamışlardır. Geliştirdikleri tek konvolüsyon katmanına sahip model, eğitim örneklerinden ayrık kosinüs dönüşümü (Discrete Cosine Transformation - DCT) benzeri modelleri verimli bir şekilde öğrenmiştir. Geliştirdikleri modeli SVM sınıflandırma yönteminden faydalanarak literatürde mevcut başka modellerle

karşılaştırmışlar ve etkinliğini test etmişlerdir. Elde ettikleri sonuçlar geliştirdikleri modelin diğer modellere kıyasla ayırt edici özellikleri daha iyi çıkarabildiğini ve iyi bir kıyaslama performansı elde edebildiğini göstermiştir.

Yadav ve Jadhav [8], sağlıklı, bakteriyel zatürre ve viral zatürre hastalığına sahip bireylere ait akciğer X-ray görüntülerini sınıflandırmak için CNN yöntemlerinden faydalanmayı amaçlamışlardır. Çalışmalarında transfer öğrenimi için VGG16, InceptionV3 sinir ağlarını ve sıfırdan bir kapsül sinir ağı öğrenimini kullanarak X-ray görüntülerini sınıflandırmışlardır. Elde ettikleri sonuçları karşılaştırmak için yerel rotasyonlu doğrusal destek vektör makinesi sınıflandırıcısı ve yönlendirme gerektirmeyen öznitelikler yöntemini kullanmışlardır. Elde ettikleri sonuçlar CNN tabanlı transfer öğreniminin her üç yöntemden daha iyi sonuçlar verdiğini göstermiştir. CNN tabanlı transfer öğrenme yöntemini kapsül sinir ağı yönteminin izlediğini gözlemlemişlerdir.

Dutta ve arkadaşları [9], CNN tabanlı, bilgisayar destekli tespit veya teşhis (computer-aided detection or diagnosis - CAD) sistemlerinin etkinliğini değerlendirmişlerdir. Değerlendirme için üç farklı veri seti ve çeşitli CAD sistemleri kullanmışlardır. Transfer öğrenme ile ince ayar yaptıkları CNN'lerden faydalananak meme kanseri teşhisi, akciğer nodülü tespiti ve prostat kanseri lokalizasyonu gibi işlemleri başarı ile gerçekleştirmişlerdir. CNN'lerin tıbbi görüntülerin analizindeki başarısının oldukça iyi olduğunu kanıtlamışlardır.

Huang ve Liao [10], sağlıklı ve hasta bireylerden elde edilmiş akciğer BT veya akciğer röntgen görüntülerinden faydalananak COVID-19 hastalığını çalışmalarında sundukları LightEfficientNetV2 modeli kullanarak tespit etmeye çalışmışlardır. Sundukları modelin etkinliğini değerlendirmek için InceptionV3, ResNet50V2, Xception, DenseNet121, MobileNetV2, EfficientNet-B0 ve EfficientNetV2 dahil olmak üzere literatürde mevcut yedi farklı CNN ağını çalışmalarına dahil etmişlerdir. Sundukları LightEfficientNetV2 modeli akciğer röntgen görüntüleri ile gerçekleştirdikleri çalışmada %98,3 doğrulukla, BT görüntüleri ile gerçekleştirdikleri çalışmada %97,4 doğrulukla diğer modelleri geride bırakmıştır.

Nasiri ve Alavi [11], göğüs röntgeni görüntülerini kullanarak COVID-19'u tespit etmek için derin öğrenmeye dayalı yeni bir yöntem sunmuşlardır. Bu yöntemde göğüs röntgen

görüntüleri farklı CNN modellerinden geçirilerek görüntülere ait öznitelik vektörleri elde edilmiştir. Daha sonra bu öznitelik vektörlerinin öznitelik sayıları varyans analizi (analysis of variance - ANOVA) yöntemi kullanılarak azaltılmıştır. Bu azaltılmış vektörler, eXtreme Gradient Boosting (XGBoost) makineli öğrenme yöntemi kullanılarak sınıflandırılmıştır. En iyi değerler DenseNet169 CNN modelinden elde edilmiştir. DenseNet169, ANOVA yöntemiyle birleştirildiğinde iki sınıflı sınıflandırmada %98,7, çok sınıflı sınıflandırmada ise %92,0 doğruluk değerine ulaşmıştır.

El-Kenawy ve arkadaşları [12], göğüs bilgisayarlı tomografi görüntülerini kullanarak COVID-19'u doğru bir şekilde teşhis etmeyi amaçlamışlardır. Bu amaçla, AlexNet sinir ağını kullanarak BT görüntülerinin özniteliklerini çıkarmışlardır. Çıkardıkları bu özniteliklerden sınıflandırmaya en çok etki eden öznitelikleri stokastik fraktal aramaya (Stochastic Fractal Search - SFS) dayalı kılavuzlu balina optimizasyon algoritması (Guided Whale Optimization Algorithm - WOA) kullanarak seçmişlerdir. Ardından seçtikleri bu öznitelikleri dengelemişlerdir. Son olarak, dengeledikleri bu öznitelikleri destek vektör makinesi (Support Vector Machine – SVM), k-en yakın komşu (K-Nearest Neighbor - KNN), sinir ağı (Neural Network - NN), karar ağacı (Decision Tree – DT) sınıflandırıcılarıyla sınıflandırmışlardır. Bu dört sınıflandırıcılardan elde edilen tahminleri bir araya getiren parçacık sürü optimizasyonuna (Particle Swarm Optimization - PSO) dayanan rehberli WOA'yı kullanarak nihai sınıflandırma sonuçlarını elde etmişlerdir. Geliştirdikleri bu sistemle 0,995 AUC değerine ulaşmışlardır.

Iraji ve arkadaşları [13], akciğer röntgeni görüntülerini kullanarak COVID-19, zatürre ve sağlıklı bireylere ait görüntüleri teşhis edebilecek derin evrişimli sinir ağlarına dayanan hibrit bir yaklaşım geliştirmişlerdir. İlk olarak, derin evrişimli sinir ağını kullanarak görüntülerin özniteliklerini çıkarmışlardır. Daha sonra ikili diferansiyel meta-sezgisel algoritma kullanarak en iyi 340 özelliği seçmişlerdir. Sonra seçilen bu 340 özelliği SVM sınıflandırıcısı kullanarak sınıflandırmışlardır. Sınıflandırmalar sonucunda %99,4 doğruluk, %99,1 duyarlılık ve %99,5 özgüllük elde etmişlerdir.

Pramanik ve arkadaşları [14], göğüs röntgeninden pnömoni tespiti yapmak için bilgisayar destekli bir teşhis sistemi geliştirmişlerdir. Geliştirdikleri sistemde ilk olarak ince ayar yapılmış, önceden eğitilmiş ResNet50 sinir ağını kullanarak akciğer görüntülerine ait öznitelikleri elde etmişlerdir. Elde ettikleri bu özniteliklerden en bilgilendirici olanlarını

geliştirdikleri adaptif ve aturstik parçacık sürüsü optimizasyonu (AAPSO) algoritması kullanarak ilk olarak 173 daha sonra 163 öznitelik seçmişlerdir. Sonuç olarak ResNet50 sinir ağının AAPSO algoritması ile birleştirildiğinde seçilen 173 öznitelik için %98,0, 163 öznitelik için %98,3 doğruluk oranı elde etmişlerdir.

Aslan ve arkadaşları [15], akciğer röntgen görüntülerinden faydalananarak COVID-19 ve zatürreyi erkenden, yüksek doğrulukla ve otomatik olarak teşhis edecek, radyologların işlerini kolaylaştıracak bir sistem geliştirmeyi amaçlamışlardır. Bu çalışma için ilk olarak akciğer röntgen görüntülerini on üç farklı CNN modeli kullanarak normalleştirmişlerdir. Daha sonra, yinelemeli komşuluk bileşen analizi (Iterative Neighborhood Component Analysis - INCA) ve yinelemeli Relief (Iterative Relief - IRF) öznitelik seçme yöntemlerini kullanarak normalleştirilmiş veri kümelerindeki bilgilendirici olmayan verileri ortadan kaldırmışlardır. Son olarak, küçültülmüş boyutlu veri kümelerini bir KNN sınıflandırıcı kullanarak sınıflandırmışlardır. Bu sınıflandırmalar sonucunda VGG16 sinir ağı ve INCA öznitelik seçime yöntemi kullanarak gerçekleştirdikleri analizde %99,1 doğruluk değeri elde etmişlerdir.

Benyahia ve arkadaşları [16], deri lezyonlarını sınıflandırmak için ISIC 2019 ve PH2 olmak üzere iki farklı veri setini kullandıkları bir çalışma yürütmüşlerdir. Bu çalışmada ilk olarak, deri lezyon görüntülerini önceden eğitilmiş 17 farklı CNN mimarisinden geçirerek deri lezyonu görüntülerini temsil eden öznitelik vektörlerini elde etmişlerdir. Daha sonra bu öznitelik vektörlerini 24 farklı makine öğrenimi sınıflandırıcılarını kullanarak sınıflandırmışlardır. Sınıflandırmalar sonucunda ISIC 2019 veri seti için DenseNet201 sinir ağı ayrı ayrı Fine KNN ve Cubic SVM ile birleştirildiğinde sırasıyla %92,3 ve %91,7 doğruluk sonuçlarına ulaştığını gözlemlemişlerdir.

Akram ve arkadaşları [17], cilt lezyonu görüntülerini doğru bir şekilde sınıflandıran bir sistem geliştirmek için dört farklı dermoskopik görüntü veri seti (PH2, ISIC-MSK, ISIC-UDA, ISBI-2017) kullanmışlardır. İlk olarak bu dermoskopik görüntülerdeki lezyonları segmentlere ayırıp lezyon bölgelerini çıkarmışlardır. İkinci olarak, Densenet201, Inception-Resnet V2, Inception V3 sinir ağlarını kullanarak bu parçalı görüntülerin öznitelik vektörleri çıkarmışlardır. Daha sonra, entropi kontrollü komşuluk bileşen analizi (entropy-controlled neighborhood component analysis - ECNCA) yöntemini kullanarak öznitelik vektörlerinin öznitelik sayılarını azaltmışlardır. Son olarak bu indirgenmiş

öznitelikleri Fine KNN (F-KNN), Ensemble Subset KNN (ES-KNN) ve SVM olmak üzere 3 farklı sınıflandırıcı kullanarak sınıflandırmışlardır. PH2, ISIC-MSK, ISIC-UDA veri setleri için F-KNN ile gerçekleştirilen sınıflandırmalar sonucunda sırasıyla %98,8, %99,2, %97,1 doğruluk değerleri, ISBI-2017 veri seti için ES-KNN ile gerçekleştirilen sınıflandırma sonucunda %95,9 doğruluk değeri elde etmişlerdir.

Khanna ve arkadaşları [18], ultrason görüntülerini kullanarak meme tümörlerini iyi huylu, kötü huylu veya normal olarak sınıflandırmak için bir yaklaşım geliştirmişlerdir. İlk olarak, ResNet-50 önceden eğitilmiş CNN modelini kullanarak görüntülerin özniteliklerini çıkarmışlardır. Daha sonra ikili gri kurt optimizasyon algoritmasını (Binary Gray Wolf Optimization - BGWO) kullanarak etkili öznitelikleri seçmişlerdir. Son olarak çeşitli sınıflandırıcılar kullanarak seçilen öznitelikleri iyi huylu, kötü huylu ve normal olarak sınıflandırmışlardır. Sınıflandırmalar sonucunda ikinci dereceden SVM sınıflandırıcısı ile gerçekleştirdikleri deneylerde %84,6 doğruluk değeri elde etmişlerdir.

Benzer şekilde Alhussan ve arkadaşları [19], ultrason görüntülerini kullanarak meme tümörlerini iyi huylu, kötü huylu veya normal olarak sınıflandırmak için yeni bir yaklaşım geliştirmişlerdir. Ön işleme olarak CNN modellerinin öğrenimini daha iyi bir hale getirmek için veri artırma işlemi gerçekleştirmişlerdir. Daha sonra GoogleNet modelini kullanarak arttırdıkları görsellerin özniteliklerini çıkarmışlardır. Sonrasında kepçe boğazlı (hybrid of dipper throated) ve PSO algoritmalarının bir karışımını kullanarak sınıflandırmada en etkili öznitelikleri seçmişlerdir. Son olarak, çeşitli sınıflandırıcılar kullanarak seçilen öznitelikleri iyi huylu, kötü huylu ve normal olarak sınıflandırmışlardır. Sınıflandırmalar sonucunda %98,1 doğruluk değeri elde etmişlerdir.

Agraval ve Chandra [20], BT görüntülerinin rahim ağzı kanseri hastalığına sahip bireylere ait olup olmadığını tespit etmek amacıyla bir sistem geliştirmişlerdir. İlk olarak BT görüntüleri üzerindeki ilgi alanlarını seçmek için görüntülere Otsu segmentasyonu yöntemi uygulamışlardır. Daha sonra Otsu segmentasyonu uyguladıkları görüntülerin ilgi alanlarının parlaklığını arttırmak için bir aktif kontur modeli (Active Contour Model - ACM) uygulamışlardır. Daha sonra bu yeni görüntülerin gri düzey birlikte oluşum matrislerini ve görüntülerin öznitelik vektörlerini elde etmişlerdir. Bunu takiben Yapay Arı Kolonisi (Artificial Bee Colony - ABC) algoritması yardımıyla öznitelik vektöründen sınıflandırmayı en çok etkileyen öznitelikleri seçip KNN, lineer SVM, Gaussian SVM

sınıflandırma yöntemlerinden faydalananarak sınıflandırmışlardır. Sınıflandırma sonucunda KNN sınıflandırıcısı için %97, Lineer SVM sınıflandırıcısı için %93, Gaussian SVM sınıflandırıcısı için %99 doğruluk değeri elde etmişlerdir.

Priya ve Ramaprabha [21], meme kanserini başlangıç aşamasında tespit etmek ve meme kanserinden kaynaklanan ölüm oranlarını önemli ölçüde azaltabilmek için mamografi görüntülerini kullanarak rezidüel ağ ile derin segmentasyon (deep segmentation with residual network - DS-RN) yöntemine dayalı meme kanseri teşhis modeli sunmuşlardır. Sundukları bu DS-RN modeli, ön işleme, daha hızlı bölge tabanlı evrişim sinir ağı (Faster Region based Convolution Neural Network - Faster R-CNN), öznetelik çıkarma ve sınıflandırma basamaklarını içermektedir. Sınıflandırma için karar ağacı sınıflandırıcısı kullanmışlardır. Sundukları bu modeli iyileştirmek için Mini-MIAS veri seti üzerinde detaylı bir simülasyon işlemi gerçekleştirmişlerdir. Deneyler sonucunda %98,86 doğruluk, %100 özgüllük, %98,15 hassasiyet değeri elde etmişlerdir.

Elsawah ve arkadaşları [22], fundus görüntülerini kullanarak diyabetik retinopati'nin (DR) derecelerini (hafif, orta, şiddetli veya proliferatif diyabetik retinopati (PDR)) sınıflandırmak için bir derin öğrenme yaklaşımı geliştirmişlerdir. Çalışmalarında ISBI'2018 Hint Diyabetik Retinopati Görüntü Veri Kümesinden (ISBI'2018 Indian Diabetic Retinopathy Image Dataset - IDRiD) faydalanmışlardır. Bu çalışmada yazarlar ön işleme olarak fundus görüntülerine yoğunluk normalizasyonu ve görüntüleri çeşitlendirmek için genişletme (augmentation) işlemi uygulamışlardır. Daha sonra yazarlar işlenmiş bu görüntüleri ResNet-50 sinir ağından geçirerek görüntülerin özneteliklerini çıkarmışlardır. Bu öznetelikleri piksel bazında ileri beslemeli sinir ağı (Pixel-Wise Feedforward Neural Network) ve ikili doğrusal çekirdek ile desteklenen vektör makinesi (Binary Linear Kernel Supported Vector Machine) sınıflandırıcılarını kullanarak sınıflandırmışlardır. Sınıflandırmalar sonucunda en yüksek %86,67 doğruluk elde etmişlerdir.

Beheshti ve arkadaşları [23], yaptıkları çalışmada hafif bilişsel bozukluğun (mild cognitive impairment - MCI) Alzheimer hastalığına dönüşüp dönüşmeyeceğini erken teşhis edebilen bilgisayar destekli bir teşhis sistemi geliştirmişlerdir. Çalışmalarında manyetik rezonans görüntülerinden oluşan Alzheimer Hastalığı Nörogörüntüleme Girişimi (ADNI) veri setinden faydalanmışlardır. Geliştirdikleri sistemde başlangıçta bu

manyetik rezonans görüntüleri üzerinde ön işleme yapmışlar ve daha sonra görüntülerin voksellerini kullanarak bu görüntülerden öznitelik vektörünü çıkarmışlardır. Çıkardıkları bu öznitelik vektörü 36539 öznitelikten oluşmaktadır. Boyutu oldukça büyük olan bu öznitelik vektörlerinin boyutunu t-test yöntemine dayalı öznitelik sıralaması ve genetik algoritmaya dayalı öznitelik seçime yöntemi kullanarak 36539 öznitelik 1913 özniteliğe düşürmüşlerdir. Boyutsal olarak azaltılmış bu öznitelik vektörlerini SVM sınıflandırıcısını kullanarak sınıflandırmışlardır. Sonuçlar, geliştirdikleri bu sistemin hafif bilişsel bozukluğun Alzheimer hastalığına dönüşüp dönüşmeyeceğini başarılı şekilde ayırt edebildiğini göstermiştir. Ancak elde edilen bu öznitelik değerlerindeki azalma yüzdesel olarak nispeten iyi olsa da sayı değeri olarak halen oldukça yüksektir.

Yukarıda bahsedilen akademik çalışmalar ve literatürde mevcut benzer çalışmalar CNN benzeri yapay zeka yaklaşımlarının hastalıklara ait tıbbi görüntüleri çeşitli yöntemlerden faydalananak başarılı şekilde sınıflandırabildiğini göstermiştir.

1.3. Problemin Durumu

Tıbbi görüntülerin çeşitliliği ve karmaşıklığı, bu görüntülerin analizinin anatomik ve teknik bilgiye sahip bir uzman ya da radyolog tarafından gerçekleştirilmesini gerektirmektedir. Ancak dünya genelindeki uzman sayısının hızla artan dünya nüfusu karşısında yetersiz kalması, bilim insanlarını uzmanların ve radyologların iş yükünü hafifletecek yeni analiz yöntemleri araştırmaya itmiştir. Son zamanlarda bilgisayar teknolojilerindeki gelişmeler ve yapay zekâ alanındaki ilerlemeler görüntü ve sinyallerin yapay zekâ tabanlı yaklaşımlarla analiz edilmesini ve bu sayede hastalıkların hızlı ve doğru bir şekilde teşhis edilebilmesini sağlamıştır. Özellikle evrimsel sinir ağlarının geliştirilmesi görüntü verilerinin etkin bir şekilde analiz edilmesini ve sınıflandırılmasını kolaylaştırmıştır. “Literatür Taraması” bölümünde de yapay zekâ ve CNN tabanlı akademik çalışmaların başarısından detaylı olarak bahsedilmiştir. Ancak CNN ve benzeri yapay zekâ modellerinin yapılarındaki parametre sayısının fazlalığı sebebiyle oluşan işlemsel yük çok fazladır. Bu sebeple bu türden modellerin gerçekleşmesi için ihtiyaç duyulan fiziksel donanımların işlem kapasitelerinin oldukça yüksek olması gerekmektedir. Başta görüntü ve video sınıflandırma uygulamaları olmak üzere çoğu uygulamada GPU tabanlı donanımların kullanılması zorunlu hale gelmektedir. Bu türden sistemlerin maliyetlerinin oldukça yüksek olması yapay zekâ tabanlı sistemlerin

yaygınlaşmasının önünde önemli bir engel teşkil etmektedir. Literatürde mevcut CNN ve yapay zekâ modellerinin işlemsel yükünü hafifletmek için kullanılan yöntemler, işlem yükünü bir nebze hafifleterek sınıflandırma performansını olumlu etkilese de yeterli olmadığı görülmektedir. Ek olarak işlemsel yükü hafifletmek için geliştirilen yöntemler sadece tek bir görüntüleme modalitesi ile elde edilmiş tıbbi görüntüler üzerinde test edilmiştir. Geliştirilen bu yöntemlerin etkinliği, farklı görüntüleme yöntemleri kullanılarak elde edilmiş tıbbi görüntüler üzerinde değerlendirilmemiştir. CNN ve benzeri yapay zekâ modellerinin yapılarındaki parametre sayısının fazlalığı sebebiyle oluşan işlemsel yük göz önüne alındığında her farklı hastalık türü için yeni bir yöntem geliştirmek oldukça zahmetli ve maliyetlidir.

Bu yüzden farklı tipteki tıbbi görüntüleri kullanarak hastalıkları yüksek doğrulukla teşhis edebilecek, tıp profesyonellerinin iş yükünü ve muayene sürelerini azaltacak, özellikle daha alt seviyedeki sağlık personelinin hastalık teşhisi koymalarına destek olacak, daha düşük maliyetli donanımlar üzerinde gerçekleştirilecek yenilikçi bir sistem geliştirilmesi büyük önem taşımaktadır.

1.4.Araştırmanın Amacı

Bu çalışmada öznitelik çıkarma, öznitelik sıralama, öznitelik seçme ve sınıflandırma işlemlerinin kombine bir şekilde kullanılması yoluyla tıbbi görüntülerin çok az öznitelikle, hızlı ve yüksek doğrulukla sınıflandırılmasını sağlayan ve bu yolla düşük maliyetli donanımlar üzerinde gerçekleştirilebilecek bir karar destek sistemi önerilmektedir. Sunulan sistem sayesinde tıbbi görüntü verilerinin çok az sayıda öznitelige indirgenmesi mümkün hale gelmektedir. Öznitelik sayısındaki düşüş, oldukça yüksek boyuta sahip olan görüntü verilerinin CNN ve benzeri karmaşık derin öğrenme modelleri ile sınıflandırılması yerine, bu görüntü verilerini temsil eden çok daha düşük boyutlu öznitelik vektörlerinin daha basit ve işlemsel karmaşıklığı çok daha düşük makine öğrenmesi modelleriyle sınıflandırılmasına imkân sağlayacaktır.

1.5. Araştırmanın Önemi

Bu tez çalışmasında gerçekleştirilmesi hedeflenen karar destek sistemi planlanan şekilde geliştirildiğinde, hastanelere kolaylıkla entegre edilebilecek, tıp profesyonellerinin iş


yükünü ve muayene sürelerini azaltacak, özellikle daha alt seviyedeki sağlık personelinin hastalık teşhisi koymalarına destek olacak bir sistem gerçekleştirilmiş olacaktır. Böylece, özellikle gelişmemiş ya da gelişmekte olan ülkelerde teşhis ve tedavideki gecikmelerden kaynaklanan mortalite ve morbidite oranlarının düşüşüne katkı sağlanmış olacaktır.



2. BÖLÜM

YÖNTEM VE MATERYAL

Bu çalışmada özellik çıkarma, özellik sıralama, özellik seçme ve sınıflandırma olmak üzere dört ana aşamadan oluşan bir karar destek sistemi yaklaşımı sunulmaktadır. Sunulan yaklaşımın akış şeması Şekil 2.1'de görülmektedir. Öznitelik çıkarma adımında bu çalışmada kullanılan veri setlerindeki tüm tıbbi görüntüler için AlexNet ve ResNet-101 CNN modelleri kullanılarak ayrı ayrı sayısal değerlerden oluşan öznitelik vektörleri oluşturulmuştur. Daha sonra her bir tıbbi görüntü için ilgili görüntüye ait AlexNet ve ResNet-101 modellerinden elde edilen öznitelik vektörleri tek bir vektör içerisinde peş peşe birleştirilerek yeni bir öznitelik vektörü daha oluşturulmuştur. Toplamda sadece bir veri seti için öznitelik vektörlerinden oluşan 3 farklı veri seti elde edilmiştir. Öznitelik sıralama adımında oluşturulan bu veri setlerindeki özniteliklerin boyutunu küçültmek için iki örneklemlili z-test yöntemi kullanılmıştır. İki örneklemlili z-test yöntemi ile sınıflar arasındaki farklılığı belirgin derecede ortaya koyan öznitelikler seçilerek öznitelik vektörlerinin boyutu azaltılmıştır. Öznitelik seçme adımında boyutu azaltılmış bu öznitelik vektörlerindeki özniteliklerden sınıflandırmada etkili olanlar, binary (ikili) genetik algoritma (BGA) yöntemi kullanılarak seçilmiştir. Böylelikle başlangıçta CNN modelleri kullanılarak üretilen öznitelik vektörlerinin boyutu yaklaşık %90 oranında küçültülmüştür. Son olarak sınıflandırma adımında seçilen bu en iyi öznitelikler 4-katlı çapraz doğrulama ile KNN ve SVM sınıflandırma yöntemleri kullanılarak sınıflandırılmış ve teşhis kararı oluşturulmuştur. Sunulan karar destek sisteminin aşamaları ve kullanılan yöntemlerin detayları aşağıda ayrıntılı bir şekilde açıklanmıştır [24].



Şekil 2.1. Sunulan yaklaşımın akış şeması

2.1. Veri Setleri


Bu çalışmada sunulan yaklaşımın etkinliğini değerlendirmek için çeşitli görüntüleme modaliteleri kullanılarak elde edilmiş üç farklı veri seti kullanılmıştır. Kullanılan veri setlerinin özellikleri aşağıdaki şekildedir;

VeriSeti-1: Bu veri seti sağlıklı ve zatürre çocuklardan toplanan 3,883 zatürre (2,538 bakteriyel zatürre görüntüsü, 1,345 viral zatürre görüntüsü) ve 1,349 normal olmak üzere toplam 5,232 adet göğüs x-ray görüntüsü içermektedir [6]. Dengeli bir veri seti oluşması açısından bu çalışmada 1340 zatürre, 1340 normal olmak üzere toplam 2680 adet rastgele seçilmiş x-ray görüntüsü kullanılmıştır. Şekil 2.2. (a)' da bu veri setindeki sağlıklı bir hastaya ait göğüs x-ray görüntüsü görülmektedir. Şekil 2.2 (b)'de ise bu veri setindeki zatürre hasatlığına sahip bir hastaya ait göğüs x-ray görüntüsü görülmektedir.

VeriSeti-2: Bu veri seti ISIC archive tarafından sağlanan, halka açık, farklı deri hasatlıklarına ait dermatolojik görüntüler içeren çok geniş bir veri setidir [25]. Bu çalışmada ISIC archive veri setinden rastgele seçilmiş 1500 malignant (kötü huylu lezyon), 1500 benign (iyi huylu lezyon) olmak üzere toplam 3000 adet dermatolojik görüntü kullanılmıştır. Şekil 2.2. (c)'de bu veri setinde bulunan benign bir deri lezyonu

görüntüsü görülmektedir. Şekil 2.2 (d)' de ise bu veri setinde bulunan malignant bir deri lezyonu görüntüsü görülmektedir.

VeriSeti-3: Bu veri seti 25 ve 75 yaş aralığındaki 600 kadın hastadan elde edilmiş 780 adet meme ultrason görüntüsünden oluşmaktadır [26]. Görüntüler normal, benign (iyi huylu lezyon) ve malignant (kötü huylu lezyon) olmak üzere üç sınıfa ayrılmıştır. Bu çalışmada ikili sınıflandırmaya odaklanıldığı için 437 benign, 211 malignant olmak üzere toplam 648 adet meme ultrason görüntüsü kullanılmıştır. Şekil 2.2. (e)'de bu veri setinde bulunan benign ultrason görüntüsü görülmektedir. Şekil 2.2 (f)' de ise bu veri setinde bulunan malignant ultrason görüntüsü görülmektedir.



Şekil 2.2. Bu çalışmada kullanılan veri setlerine ait örnek görüntüler


2.2. Öznitelik Çıkarma

Öznitelik çıkarma işlemi, çeşitli yöntemlerinden faydalanılarak, karmaşık ve yüksek boyutlu bir verideki bileşenlerin aynı veya farklı bir formadaki daha kolay anlaşılabilir ve işlenebilir özniteliklere dönüştürülmesi işlemidir. Öznitelik çıkarma işlemi sayesinde gereksiz veya tekrarlayan bilgiler ortadan kaldırılarak hesaplama maliyeti azaltılabilir ve veri setlerinin işlenmesi daha etkili hale gelebilir. Öznitelik çıkarma işlemi için frekans

analizi, temel bileşen analizi, özdeğer ayrışımı, wavelet dönüşümü, istatistiksel yöntemler, autoencoder ve derin öğrenme yöntemleri gibi çok çeşitli yöntemler mevcuttur. Son zamanlarda yapılan çalışmalar göz önüne alındığında özellikle CNN modelleri kullanılarak gerçekleştirilen öznitelik çıkarma yöntemlerinin oldukça etkili sonuçlar verdiği görülmektedir [27], [28].

2.2.1. Evrişimsel Sinir Ağları ile Öznitelik Çıkarma

Evrişimsel sinir ağları (Convolutional Neural Network - CNN) çok katmanlı sinir ağlarıdır. Özellikle görüntülerin analiz edilip sınıflandırılmasında sıklıkla kullanılırlar. Girişlerine verilen görüntüleri yapılarındaki giriş, konvolüsyon, indirgeme, düzleştirme, tam bağlı ve çıkış katmanlarından geçirerek görüntülere ait öznitelikleri çıkartırlar. Çıkardıkları bu öznitelikleri analiz ederek görüntülerin sınıflarını öğrenirler. Öğrenme süreci bittiğinde ise artık girişlerine verilen görüntülerin sınıfı ile ilgili yüksek doğrulukta kararlar üretebilirler. Şekil 2.3. de bir CNN modelinin genel yapısı görülmektedir [7], [29].




Şekil 2.3. Bir CNN modelinin genel yapısı

CNN'lerin katmanlarının görevleri şu şekildedir;

Giriş katmanı: Giriş katmanı bir CNN modelinin ilk katmanıdır. İşlenecek görüntüler ilk olarak giriş katmanına verilir. Bu katmanda görüntülere herhangi bir işlem uygulanmadan görüntüler sonraki katmanlara aktarılır.

Konvolüsyon katmanı: Konvolüsyon katmanı bir CNN modelinin en önemli katmanıdır. Çünkü giriş görüntüsüne ait öznitelikler peş peşe sıralanmış konvolüsyon katmanları vasıtasıyla elde edilir. Bu katmanlarda görüntülere, elde edilmek istenen özniteliklere uygun olarak farklı boyutlarda filtreler uygulanır. Uygulanacak filtrelerin boyutu giriş görüntüsünden küçüktür. Filtre, işlenen görüntünün sol üst köşesine gelecek şekilde yerleştirilir. Filtre ve görüntünün üst üste gelen bütün değerleri çarpılıp toplanır. Elde edilen değer filtreleme sonucu oluşacak önemli öznitelik değerlerini taşıyan öznitelik matrisinin sol üst köşesindeki ilk değerdir. Her defasında bu filtre bir birim sağa ötelenerek hesaplamalar yapılır. İlk satır bittiğinde yeni görüntünün birinci satırının değerleri de elde edilmiş olur. Daha sonra filtre öznitelik matrisinin ikinci satır değerlerini oluşturmak için giriş görüntüsünün ikinci satırının en solundan yeniden başlar. Bu işlemler bütün görüntü boyunca tekrarlanır. Konvolüsyon katmanının çıkışında giriş görüntüsü ile ilgili önemli özellikleri içeren ve giriş görüntüsünden daha küçük boyutta yeni bir matris elde edilmiş olur. Şekil 2.4.'de 4x4 boyutunda bir giriş görüntüsü ile 3x3 boyutunda bir filtre arasındaki konvolüsyon işlemi ile öznitelik matrisinin oluşturulması basamakları adım adım gösterilmiştir. Elde edilen bu yeni öznitelik matrisi kullanılan modelin yapısına bağlı olarak bir sonraki konvolüsyon katmanına ya da indirgeme katmanına giriş olarak aktarılır.




Şekil 2.4. Konvolüsyon işlemi

İndirgeme katmanı: İndirgeme katmanları CNN modellerinde sıklıkla kullanılan ve genellikle peş peşe sıralanmış konvolüsyon katmanlarının arasına yerleştirilen katmanlardır. İndirgeme katmanları sayesinde CNN modellerinin hesaplama maliyetleri oldukça azaltılabilmektedir. Genellikle kendinden önceki katmanın çıkışında elde edilen öznitelik matrisinin boyutunu indirmek ve bu matristeki önemli bilgileri çıkarmak için kullanılırlar. İndirgeme işlemi için kullanılan pek çok yöntem mevcuttur. Literatürde en sık kullanılan yöntemler ise maksimum indirgeme (max pooling) ve ortalama indirgeme (average pooling) yöntemleridir.


Maksimum indirgeme, indirgeme işlemi yapılacak matris üzerinde gezen filtrenin kapsadığı bölgedeki en yüksek değeri alarak yeni öznitelik matrisinin

oluşturulması işlemidir. Şekil 2.5. de 4x4 boyutundaki bir matrise 2x2 boyutunda bir filtre ile maksimum indirgeme işlemi uygulanması görülmektedir.



Şekil 2.5. Maksimum indirgeme işlemi


Ortalama indirgeme, indirgeme işlemi yapılacak matris üzerinde gezen filtrenin kapsadığı bölgedeki değerlerin ortalaması alınarak yeni öznitelik matrisinin oluşturulması işlemidir. Şekil 2.6. da 4x4 boyutundaki bir matrise 2x2 boyutunda bir filtre ile ortalama indirgeme işlemi uygulanması görülmektedir.



Şekil 2.6. Ortalama indirgeme işlemi

Düzleştirme katmanı: Düzleştirme katmanının görevi peş peşe sıralanmış konvolüsyon ve indirgeme katmanlarının sonucunda elde edilmiş önemli öznitelikleri içeren iki boyutlu öznitelik matrisini, vektör haline getirerek tam bağlı katmanlara aktarmaktır.

Şekil 2.7. de konvolüsyon ve indirgeme işlemleri sonrasında elde edilen öznetelik matrisinin düzleştirilmesi işlemi görülmektedir.







Şekil 2.7. Düzleştirme işlemi

Tam bağlı katmanlar: Tam bağlı katmanlar CNN modellerindeki en temel yapılardan biridir. Her tam bağlı katman CNN modelinin yapısına bağlı olarak bir dizi nöron içerir. Bu nöronlar kendinden önceki ve sonraki katmanlarda bulunan bütün nöronlarla bağlantılıdır. Düzleştirme katmanında sıralanan özneteliklerin değerleri ilk tam bağlı katmandaki nöronlara aktarılır. Tam bağlı katmanlarda gerçekleşen bir dizi hesaplamalar ile CNN modeli giriş görüntüsündeki oldukça karmaşık ilişkileri öğrenir ve geneller. Bu genellemeler sayesinde CNN modelinin çıkışında üretilecek nihai kararın temelleri oluşturulur.

Çıkış katmanı: Tam bağlı katmanların sonundaki nöronlardan faydalanarak ve çeşitli aktivasyon fonksiyonları kullanarak CNN modelinin çıkışındaki nihai kararın üretildiği katmandır. Nihai kararın üretilmesinde kullanılan pek çok aktivasyon fonksiyonu mevcuttur. Bu fonksiyonlardan bazıları sigmoid fonksiyonu, hiperbolik tanjant fonksiyonu, doğrultulmuş lineer birim (Rectified Linear Unit - ReLU) fonksiyonu, softmax fonksiyonudur. Tablo 2.1. de bu fonksiyonların denklemleri ve grafikleri görülmektedir.

Tablo 2.1. Aktivasyon fonksiyonlarının denklemleri ve grafikleri

Fonksiyon	Denklem	Grafik
Sigmoid Fonksiyonu	$f(x) = \frac{1}{1 + e^{-x}}$	 The graph shows the Sigmoid function, which is an S-shaped curve. It is plotted on a coordinate system with x ranging from -10 to 10 and y (labeled Sigmoid(x)) ranging from 0 to 1. The curve starts near 0 for negative x, passes through (0, 0.5), and approaches 1 for positive x.
Hiperbolik Tanjant Fonksiyonu	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	 The graph shows the Hyperbolic Tangent function, which is an S-shaped curve centered at the origin. It is plotted on a coordinate system with x ranging from -10 to 10 and y (labeled tanh(x)) ranging from -1 to 1. The curve passes through (0, 0) and approaches -1 for negative x and 1 for positive x.
ReLU Fonksiyonu	$f(x) = \max(0, x)$	 The graph shows the Rectified Linear Unit (ReLU) function. It is plotted on a coordinate system with x ranging from -10 to 10 and y (labeled ReLU(x)) ranging from 0 to 10. The function is zero for all negative x and increases linearly with a slope of 1 for all positive x.
Lineer Fonksiyon	$f(x) = x$	 The graph shows the Linear function, which is a straight line passing through the origin. It is plotted on a coordinate system with x ranging from -10 to 10 and y ranging from -10 to 10. The line has a constant slope of 1.

CNN'lerin genel yapısı bu şekildedir. Farklı CNN modelleri için tekrar eden konvolüsyon ve indirgeme katmanlarının sayıları, tam bağımlı katmanların sayısı, kullanılan aktivasyon fonksiyonları farklılık gösterebilir. Literatürde farklı amaçlara yönelik kullanılan pek çok CNN modeli mevcuttur. AlexNet, ResNet, GoogLeNet, VGGNet, MobileNet, Inception-V3 bu modellerden bazılarıdır.

Bu tez çalışmasının öznitelik çıkarma aşamasında, tıbbi görüntüleri en iyi temsil eden öznitelik vektörlerini üretmek için AlexNet ve ResNet-101 CNN ağları kullanılmıştır. Bu CNN yapılarının konvolüsyon, indirgeme ve ilk tam bağlantılı katmanları kullanılarak veri kümelerindeki görüntülere ilişkin öznitelik vektörleri oluşturulmuştur.

2.2.1.1. AlexNet Ağı ile Öznitelik Çıkarma

AlexNet, 5 konvolüsyon, 3 indirgeme katmanı ve 3 tam bağlantılı katman olmak üzere toplam 11 katmandan oluşmaktadır. AlexNet'in girişine verilecek görüntünün boyutu 227×227 olmalıdır. Bu nedenle bu çalışmada kullanılan veri setlerindeki görseller 227×227 olarak yeniden boyutlandırılmıştır. Daha sonra öznitelik çıkarma aşamasında AlexNet'in 'fc7' adı verilen tam bağlantılı katmanından veri setlerindeki görüntülere ilişkin öznitelik vektörleri elde edilmiştir. Tek bir görüntü için 'fc7' katmanından elde edilen öznitelik vektörünün uzunluğu 4096'dır. Veriseti-1, Veriseti-2 ve Veriseti-3'e ait görüntülerin AlexNet'ten geçirilmesi ile ilgili görüntü veri setini temsil eden sırasıyla 2680×4096 , 3000×4096 ve 648×4096 boyutlarında üç farklı sayısal veri seti elde edilmiştir. Bu veri setleri öznitelik sıralama aşamasında kullanılmak için kaydedilmiştir [30].

2.2.1.2. ResNet-101 ile Öznitelik Çıkarma

ResNet-101, 101 katmandan oluşmaktadır. ResNet-101'in girişine verilecek görüntünün boyutu 224×224 olmalıdır. Bu nedenle bu çalışmada kullanılan veri setlerindeki görseller 224×224 olarak yeniden boyutlandırılmıştır. Daha sonra öznitelik çıkarma aşamasında ResNet-101'in 'pool5' adı verilen 2-D global average pooling (2 boyutlu global ortalama indirgeme) katmanından veri setlerindeki görüntülere ilişkin öznitelik vektörleri elde edilmiştir. Tek bir görüntü için 'pool5' katmanından elde edilen öznitelik vektörünün uzunluğu 2048'dir. Veriseti-1, Veriseti-2 ve Veriseti-3'e ait görüntülerin ResNet-101'den geçirilmesi ile ilgili görüntü veri setini temsil eden sırasıyla 2680×2048 ,

3000x2048 ve 648x2048 boyutlarında üç farklı sayısal veri seti elde edilmiştir. Bu veri setleri öznitelik sıralama aşamasında kullanılmak için kaydedilmiştir [31].

2.2.1.3. Öznitelik Birleştirme

AlexNet ve ResNet-101 sinir ağlarının ürettiği özniteliklerin birleştirilerek daha etkin sınıflandırma sonuçları sağlayan öznitelik vektörlerinin elde edilip edilemeyeceğini değerlendirmek için AlexNet ve ResNet-101 sinir ağından elde edilen öznitelik vektörleri tek bir vektör içerisinde peş peşe birleştirilmiştir Veriseti-1, Veriseti-2 ve Veriseti-3 için sırasıyla 2680x6144, 3000x6144, 648x6144 boyutlarında yeni veri setleri elde edilmiştir. Bu veri setleri de öznitelik sıralama aşamasında kullanılmak için kaydedilmiştir.

Öznitelik çıkarma aşamasında ilgili veri seti için AlexNet ve ResNet-101 sinir ağları kullanılarak elde edilen öznitelik sayıları ve bu iki sinir ağının birleştirilmesi ile elde edilen öznitelik sayıları ve oranları Tablo 2.2'nin I numaralı sütununda görülmektedir.

Tablo 2.2. Her yöntemin veri setlerine tek tek uygulanmasından sonra elde edilen öz nitelik sayıları

		I	II	III	IV
VeriSeti-1	AlexNet	4096 (%100)	3667 (%89,5)	409 (%9,9)	366 (%8,9)
	ResNet-101	2048 (%100)	1798 (%87,8)	204 (%9,9)	179 (%8,7)
	AlexNet + ResNet-101	6144 (%100)	5553 (%90,3)	614 (%9,9)	555 (%9,0)
VeriSeti-2	AlexNet	4096 (%100)	3633 (%88,7)	409 (%9,9)	363 (%8,8)
	ResNet-101	2048 (%100)	1773 (%86,6)	204 (%9,9)	177 (%8,6)
	AlexNet + ResNet-101	6144 (%100)	5370 (%87,4)	614 (%9,9)	537 (%8,7)
VeriSeti-3	AlexNet	4096 (%100)	2871 (%70,1)	409 (%9,9)	287 (%7)
	ResNet-101	2048 (%100)	1227 (%59,9)	204 (%9,9)	122 (%5,9)
	AlexNet + ResNet-101	6144 (%100)	3933 (%64,2)	614 (%9,9)	393 (%6,4)

I: Öz nitelik çıkarma; **II:** Öz nitelik çıkarma + Öz nitelik sıralama; **III:** Öz nitelik çıkarma + Öz nitelik seçme; **IV:** Öz nitelik çıkarma + Öz nitelik sıralama + Öz nitelik seçme

2.3. Öz nitelik Sıralama

Öz nitelik sıralama işlemi, bir veri setindeki öz niteliklerin çeşitli yöntemlerden faydalanarak önem sırasına göre sıralanması işlemidir. Veri setindeki öz niteliklerin önem sırasını belirlemek, anlamsız veya gereksiz öz nitelikleri elememize yardımcı olarak sınıflandırma yöntemlerinin performansını artırabilmektedir. Bu işlem için öncelikle öz nitelikler çeşitli yöntemlerden faydalanarak önem sırasına göre sıralanır. Daha sonra sıralanan bu öz niteliklerden sınıflandırmada en etkin olanları belirlenerek bu öz niteliklerden bir alt öz nitelik seti oluşturulur. Bu alt öz nitelik seti boyut olarak ilk öz nitelik setinden daha küçük olmasına rağmen sınıflandırmada ilk veri seti ile aynı ya da daha yüksek doğruluk değeri verebilir [32].

İstatistiğe dayalı, regresyona dayalı, korelasyona dayalı, makineli öğrenme yaklaşımlarına dayalı pek çok öznitelik sıralama yöntemi mevcuttur. Tablo 2.3.'te bu yaklaşımlara dayalı farklı öznitelik sıralama yöntemleri görülmektedir [33-35].

Tablo 2.3. Öznitelik seçme yöntemleri ve bu yöntemlerin yaklaşımları

YAKLAŞIM	YÖNTEM
İstatistiksel	• t-Test • z-Test • ANOVA
Regresyon	• Elastic Net Regresyonu • Ridge Regresyonu • Özyinelemeli Özelliğin Ortadan Kaldırılması Modeli (Recursive Feature Elimination - RFE)
Korelasyon	• Pearson Korelasyonu • Spearman Korelasyonu • Kendall Tau Korelasyonu
Makineli Öğrenme	• Karar Ağaçları Algoritması • Rastgele Orman Algoritması • Stacking

Kullanılacak öznitelik sıralama yöntemi, çözülmeye çalışılan problemin durumuna uygun olarak belirlenir. Bu çalışmada iki farklı grup arasında belirgin farkı ortaya çıkaran

özniteliklerin seçilmesi gerektiği için öznitelik sıralama yöntemi olarak iki örneklemlili z-test yöntemi kullanılmıştır.

2.3.1. İki Örneklemlili z-Test Yöntemi ile Öznitelik Sıralama

İki örneklemlili z-test yöntemi büyük veri kümelerinin özelliklerini sıralamak için kullanılan istatistiksel öznitelik sıralama yöntemlerinden biridir. İki örneklemlili z test yöntemi, iki farklı grup veya sınıfa ait aynı özniteliklerin ortalamalarını kullanarak, sınıflar arasındaki farkı ortaya çıkaran en iyi öznitelikleri belirler [36].

Bu tez çalışmasında öznitelik sıralama işlemi için öznitelik çıkarma aşamasında elde edilen Veriseti-1, Veriseti-2 ve Veriseti-3'e ait öznitelik vektörlerine iki örneklemlili z-test yöntemi uygulanarak sınıflandırmada etkili en iyi öznitelikler belirlenmiştir. Belirlenen bu özniteliklerle, ilgili veri setini temsil eden, daha az sayıda öznitelik içeren alt veri seti oluşturulmuştur. İki örneklemlili z-test yönteminin uygulama adımları aşağıdaki şekildedir.

- 1) İki örneklemlili z-test yöntemi ile öznitelik sıralama işlemi için ilk olarak sıfır hipotezi ve alternatif hipotez belirlenmelidir.

Sıfır hipotezi (H_0) = *n. öznitelik için sınıfların ortalaması arasında bir fark yoktur.*

Alternatif Hipotez (H_1) = *n. öznitelik için sınıfların ortalamaları arasında belirgin bir fark vardır. Bu durumda n. öznitelik iki sınıf arasında belirleyici bir özniteliktir.*

- 2) Hipotezler belirlendikten sonra öznitelik çıkarma aşamasında elde edilmiş sayısal veri setlerine sırasıyla iki örneklemlili z-test uygulanır. İki örneklemlili z-test yönteminin formülasyonu Denklem 2.1 de görülmektedir.

$$z = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \quad (2.1)$$

Burada $\bar{x}_1$, μ_1 , σ_1^2 sırasıyla birinci sınıfa ait örneklerin ortalamasını, popülasyonun ortalamasını ve popülasyonun standart sapmasını; $\bar{x}_2$, μ_2 , σ_2^2 ise sırasıyla ikinci sınıfa ait örneklerin ortalamasını, popülasyonun ortalamasını ve popülasyonun standart sapmasını temsil etmektedir.

- 3) İki örneklemlili z-test yönteminin formülasyonundan faydalanılarak ilgili veri setindeki her bir özniteliğin z-değeri hesaplandıktan sonra standart normal dağılım tablosundan faydalanılarak istatistiksel p-değerleri belirlenir. Eğer n. özniteliğin p-değeri 0,05'ten küçükse alternatif hipotez kabul edilir ve ilgili öznitelik seçilir, değilse sıfır hipotezi kabul edilir ve ilgili öznitelik seçilmez.

Öznitelik çıkarma adımıyla elde edilen tüm veri setlerine iki örneklemlili z testi yönteminin uygulanması ile veri setlerindeki sınıflandırmaya dahil edilecek öznitelik sayıları belli oranda azaltılmıştır. Bu azalma oranları ortalama Veriseti-1 için %10,8, Veriseti-2 için %12,4 ve Veriseti-3 için %35,2'dir. Tüm sayısal veri setleri için iki örneklemlili z-testi yöntemi ile özellik sıralama aşamasında elde edilen öznitelik sayıları ve özniteliklerin azalma oranları Tablo 2.2'nin II numaralı sütununda görülmektedir.

2.4. Öznitelik Seçme

Bir veri setinde pek çok öznitelik bulunabilir. Bu özniteliklerden bazıları veri setlerinin sınıfları arasındaki farkı belirgin derecede ortaya koyarken bazıları sınıflardan bağımsız değerlere sahip olabilir. Sınıflardan bağımsız değerlere sahip öznitelikler bilgilendirme açısından yetersiz ve gereksiz verilerdir. Bu öznitelikler veri setleri sınıflandırılırken işlem süresinin uzamasına ve işlem maliyetinin artmasına sebep olur. Bu yüzden veri setlerine, önemli öznitelikleri seçip, gereksiz özniteliklerden ayıracak bir yöntem uygulanmalıdır [37].

Öznitelik seçme yöntemi, özellikle büyük verilerin sınıflandırılmasında karşılaşılan işlem süresinin uzunluğu, maliyeti gibi sorunları ortadan kaldırmak ve işlem yükünü hafifletmek için kullanılan bir yöntemidir. Sınıflandırma işleminde sonuca en çok etki

eden öznitelikler belirli kriterlere göre çeşitli algoritmalar ve yöntemler kullanılarak seçilir. Böylece daha az öznitelikle önceki sınıflandırma performansıya aynı veya daha yüksek doğruluk elde edilmesi amaçlanır [37].

Öznitelik seçme yöntemleri yaklaşımlarına göre filtreleme yöntemleri, sarım yöntemleri ve gömme yöntemleri olmak üzere üç gruba ayrılır [38].

Filtreleme (Filter) Yöntemleri: İstatistiksel ölçümlerden ya da bilgi kazançlarından faydalanarak özniteliklerin değerlendirilip en iyi performansı gösterenlerin seçildiği yöntemlerdir. Filtreleme yöntemlerine korelasyon, bilgi kazancı, chi-kare istatistiği gibi yöntemler örnek olarak gösterilebilir.

Gömme (Embedded) Yöntemleri: Öznitelik seçme işlemlerinin çeşitli öğrenme algoritmalarının içine gömülerek gerçekleştirildiği yöntemlerdir. Gömme yöntemlerine regularizasyon tabanlı modeller, ağaç tabanlı modeller örnek olarak gösterilebilir.

Sarım (Wrapper) Yöntemleri: Çeşitli öğrenme algoritmalarından faydalanılarak özniteliklerin değerlendirildiği ve en iyi özniteliklerden oluşan öznitelik kümelerinin oluşturulduğu yöntemlerdir. Öğrenme algoritmaları rastgele oluşturulmuş bir başlangıç popülasyonu üzerinde başlar ve iyi öznitelikleri iterasyonlar boyunca arar. Belli bir uygunluk değeri sağlandığında en iyi sonucu veren öznitelikler de bulunmuş olur. Sarım yöntemlerine genetik algoritma, differansiyel gelişim algoritması, yapay arı kolonisi algoritması gibi yöntemler örnek olarak gösterilebilir.

2.4.1. Genetik Algoritma

Günlük hayatımızda karşılaştığımız problemler lineer ya da lineer olmayan problemlerdir. Lineer problemler deterministik yöntemlerden faydalanılarak çözülebilmektedir. Ancak gerçek hayat problemlerinin büyük bir bölümü lineer olmayan problemlerdir. Lineer olmayan problemlerin deterministik yöntemlerle çözümü ise yüksek işlem yükü ve uzun işlem süresi gibi zorluklar içermektedir. Bu yüzden lineer olmayan problemlerin üstesinden gelmek için sezgisel yöntemler geliştirilmiştir.

Sezgisel yöntemler doğadaki canlılar ilham alınarak geliştirilmiş deneme yanılma yoluyla problemin çözümünü arayan yöntemlerdir. Çözülme istenen problem ne kadar karmaşık

ve belirsiz olursa olsun sezgisel yöntemler problemin değişen koşullarına uyum sağlayarak en uygun çözümü bulabilmektedir.

En etkin sezgisel arama yöntemlerinden biri 1975 yılında ilk defa John Holland tarafından evrim teorisinden esinlenilerek geliştirilen **genetik algoritmadır**. En güçlü olan bireyin hayatta kalması ilkesine dayanan (doğal seçim) popülasyon tabanlı bir optimizasyon algoritmasıdır. En güçlü birey ilgili problem için en uygun çözümdür. İterasyonlar boyunca seçim, çaprazlama ve mutasyon operatörleri yardımıyla problemin çözümü için en uygun birey aranır. Belli bir uygunluk değerini sağlayan birey ilgili problem için en uygun çözümdür [39].

Genetik algoritmada en uygun çözüm aranırken kullanılan pek çok kavram vardır. Bu kavramlar şunlardır:

Kromozom: Genetik algoritmanın en temel bileşenidir. İlgili problemin potansiyel çözümleri kromozomlar ile temsil edilir.


Gen: Genler kromozomların alt birimleridir. İlgili problemin çözüm parametrelerini temsil ederler.

Popülasyon: Popülasyon bütün potansiyel çözümleri yani bütün kromozomları kapsayarak genetik algoritmanın çalışma alanını oluşturur.

Uygunluk Değeri: Uygunluk değeri potansiyel bir çözümün ne kadar iyi olduğunun ölçüsüdür. Ortalama kare hatası, k-en yakın komşu, destek vektör makineleri, karar ağaçları gibi çeşitli uygunluk algoritmalarından faydalanılarak elde edilir.

İterasyon: Başlangıç popülasyonundaki kromozomlardan ve genetik algoritmanın seçim, çaprazlama ve mutasyon operatörlerinden faydalanılarak yeni bir popülasyon üretilmesine bir iterasyon denir. En yüksek uygunluk değerini sağlayan kromozom üretilene kadar iterasyonlar tekrarlanır.

Şekil 2.8’de bir problemin çözümü için oluşturulmuş kromozomları (potansiyel çözümleri) ve genleri içeren örnek bir popülasyon görülmektedir.



Şekil 2.8. Gen, Kromozom ve Popülasyon

2.4.1.1. Genetik Algoritmanın Uygulama Aşamaları


Genetik algoritmanın uygulanması aşamasında ilk olarak başlangıç parametreleri belirlenmelidir. Başlangıç parametreleri gen sayısı, kromozom sayısı, popülasyon büyüklüğü, maksimum iterasyon sayısı ve maksimum uygunluk değeridir. Çözülmek istenen problemin parametre sayısı kromozomlara ait gen sayısını oluşturur. Kromozom sayısı ise kullanıcı tarafından belirlenebildiği gibi optimizasyon yöntemlerinden faydalanılarak da belirlenebilmektedir. Maksimum iterasyon sayısı ve maksimum uygunluk değeri genetik algoritmanın durma kriterlerini oluşturur ve yine kullanıcı tarafından belirlenebildiği gibi optimizasyon yöntemlerinden faydalanılarak da belirlenebilmektedir.

Şekil 2.9’da genetik algoritmanın akış şemasında da görüldüğü gibi başlangıç parametreleri belirlendikten sonra başlangıç popülasyonu rastgele parametre değerleri kullanılarak üretilir. Başlangıç popülasyonu oluşturulduktan sonra kromozomların uygunluk değerleri ortalama kare hatası, k-en yakın komşu, destek vektör makineleri, karar ağaçları gibi çeşitli uygunluk değerlendirme algoritmalarından faydalanılarak hesaplanır. Uygunluk değeri hesaplanan başlangıç kromozomları bir sonraki popülasyona

ait kromozomları üretmek için seçim, çaprazlama, mutasyon ve elitizm operatörlerine aktarılır.

Başlangıç popülasyonuna seçim, çaprazlama, mutasyon ve elitizm operatörleri uygulandıktan sonra ilk iterasyon tamamlanmış ve yeni bir popülasyon elde edilmiş olur. Yeni popülasyon oluşturulduktan sonra algoritma Şekil 2.9'da da görüldüğü gibi başa döner ve yeni popülasyondaki her kromozomun uygunluk değerleri hesaplanır. Oluşturulan kromozomlardan herhangi biri başlangıçta belirlenen uygunluk değerini sağlıyor ise en iyi çözüm bulunmuş olur ve algoritma durur.

Eğer oluşturulan kromozomlardan herhangi biri başlangıçta belirlenen uygunluk değerini sağlamıyor ise aynı işlemler en iyi çözüm bulunana kadar ya da maksimum iterasyon sayısına ulaşılan kadar tekrarlanır. Seçim, çaprazlama, mutasyon ve elitizm operatörlerinin detayları aşağıda açıklanmıştır [39].



Şekil 2.9. Genetik algoritmanın akış şeması

2.4.1.1.1 Seçim

Genetik algoritmada bir sonraki popülasyonu oluşturmak için başlangıç popülasyonundan kromozomlar çaprazlama operatörüne aktarılacak üzere uygunluk değerlerine göre seçilmelidir. Genetik algoritmada amaç her yeni popülasyonda en iyi çözüme daha yakın kromozomlar üretmek olduğundan uygunluk değeri daha yüksek olan kromozomların seçilme olasılıkları daha yüksektir. Böylece uygunluk değeri daha yüksek olan kromozomların genleri sonraki popülasyonlara aktararak her iterasyonda en iyi çözüme daha yakın kromozomların üretilmesi sağlanır. Seçim işlemi rulet yöntemi ve turnuva yöntemi olmak üzere iki farklı seçim yönteminden faydalanılarak gerçekleştirilebilmektedir.

Rulet Yöntemi

Rulet yöntemi ile seçme işlemi gerçekleştirilirken, kromozomlar uygunluk değerlerinden faydalanarak rastgele seçilirler. Her bir kromozom uygunluk değeri ile orantılı olarak rulet tekerleğinde belirli bir alan kaplar. Kromozomların rulet tekerleğinde ne kadar alan kaplayacağı Denklem 2.2 ve Denklem 2.3'ten faydalanarak hesaplanır. Tablo 2.4.'te bu hesaplamaları gerçekleştirebilmek için oluşturulmuş örnek bir popülasyondaki kromozomlar ve bu kromozomların uygunluk değerleri görülmektedir.

Tablo 2.4. Kromozomlar ve uygunluk değerleri

Kromozom	Uygunluk Değeri
x_1	$f(x_1)$
x_2	$f(x_2)$
x_3	$f(x_3)$
$\vdots$	$\vdots$
x_N	$f(x_N)$

$$F_T = \sum_{i=1}^N f(x_i) \quad (2.2)$$


$$P_i = \frac{f(x_i)}{F_T} \quad (2.3)$$

Kromozomların rulet tekerleğinde ne kadar alan kaplayacağı belirlemek için ilk olarak Denklem 2.2'den faydalanılarak bir popülasyondaki bütün kromozomların uygunluk değerleri toplanır. Burada N popülasyondaki kromozom sayısını, $f(x_i)$ i . kromozomun uygunluk değerini, F_T popülasyondaki kromozomların uygunluk değerlerinin toplamını temsil eder. Daha sonra Denklem 2.3' de görüldüğü gibi i . kromozomun rulet tekerleğinde kaplayacağı alan (P_i), i . kromozomun uygunluk değerinin bütün kromozomların uygunluk değerinin toplamına bölünmesi ile hesaplanır. P_i , i . kromozom için normalize edilmiş uygunluk değeridir. Yani bütün P_i değerlerinin toplamı bire eşittir. Tablo 2.5'te oluşturulmuş örnek popülasyondaki kromozomlar ve kromozomların normalize edilmiş uygunluk değerleri görülmektedir.

Tablo 2.5. Kromozomlar ve normalize edilmiş uygunluk değerleri

Kromozom	Normalize Edilmiş Uygunluk Değeri
x_1	P_1
x_2	P_2
x_3	P_3
$\vdots$	$\vdots$
x_N	P_N

Bütün kromozomların rulet tekerleğinde kaplayacağı alanlar belirlendikten sonra rulet tekerleği Şekil 2.10'da görüldüğü gibi oluşturulur. Rulet tekerleğinde 0 ve 1 değerini aynı nokta temsil ettiğinden $[0,1)$ kuralına bağlı kalınarak işlemler gerçekleştirilir.



Şekil 2.10. Rulet tekerleği

Rulet tekerleği oluşturulduktan sonra çevrilir ve başlangıç okuna denk gelen alandaki kromozom seçilmiş olur. İşlem tekrarlanarak çaprazlama operatörüne aktarılabacak bütün kromozomlar seçilir. Uygunluğu daha yüksek olan yani rulet tekerleğinde daha fazla alan kaplayan kromozomun başlangıç okuna denk gelme olasılığı daha yüksektir. Bu sayede bir sonraki popülasyonda oluşturulacak kromozomların, başlangıç iterasyonuna kıyasla daha yüksek uygunluk değerlerine sahip olma olasılığı yükselmiş olur. Ayrıca uygunluk değeri daha düşük olan kromozomların küçüğe olsa rulet tekerleğinde yer alması sağlanarak popülasyondaki çeşitlilik korunmuş olur.

Turnuva Yöntemi

Turnuva yöntemi rastgele seçim ve uygunluk değerlerine dayalı bir seçme yöntemidir. Popülasyon içindeki çeşitlilik korunurken, aynı zamanda uygunluk değeri daha yüksek kromozomların seçilme olasılığı yükselir. Seçilerek çaprazlama operatörüne aktarılabacak bireyler aşağıdaki adımlar izlenerek belirlenir.

1. Rastgele bir n değeri belirlenir. n değeri başlangıç popülasyonundaki kromozom sayısından küçük bir değerdir.

2. n değeri kadar kromozom başlangıç popülasyonundan rastgele seçilerek bir alt popülasyon oluşturulur.
3. Oluşturulan alt popülasyondaki kromozomlar turnuvaya sokulur. Uygunluk değeri açısından en yüksek değere sahip kromozom turnuvanın galibi olur ve çaprazlama operatörüne aktarılır.

Her turnuva seçimi, popülasyon içinden bir kromozomun seçilmesini sağlar. Yukarıdaki işlem adımları tekrarlanarak istenilen sayıda kromozom seçilip çaprazlama operatörüne aktarılır.

2.4.1.1.2 Çaprazlama

Genetik algoritmada çaprazlama operatörü ile başlangıç popülasyonundaki kromozomlardan ve rastgele seçimlerden faydalanılarak en iyi çözüme daha yakın kromozomlardan oluşan yeni bir popülasyon oluşturulması amaçlanır. Çaprazlama operatöründe yeni kromozomlar oluşturulurken kullanılan pek çok kavram vardır. Bu kavramlar şunlardır,

Ebeveyn 1: Bir sonraki popülasyonda yer alacak bir kromozomu oluşturmak için çaprazlama işlemine tabi tutulacak **birinci** kromozoma verilen addır.

Ebeveyn 2: Bir sonraki popülasyonda yer alacak bir kromozomu oluşturmak için çaprazlama işlemine tabi tutulacak **ikinci** kromozoma verilen addır.

Yavru bireyler: Çaprazlama işleminden sonra eğer tek bir kromozom elde edilmiş ise bu kromozom Yavru 1 olarak adlandırılır. Eğer iki kromozom elde edilmiş ise bu kromozomlar Yavru 1 ve Yavru 2 olarak adlandırılır.

Çaprazlama Noktası: Çaprazlama noktası sonraki popülasyonda yer alacak kromozomları oluşturmak için ebeveynlerin genetik materyallerinin birleştirileceği noktadır. Bu nokta genellikle rastgele seçilerek ebeveynler arasında gen değiş tokuşu gerçekleştirilir.

Genetik algoritmada bir sonraki popülasyonda yer alacak kromozomları oluşturmak için seçim operatöründe seçilen kromozomların genleri çaprazlama operatöründe çeşitli

çaprazlama yöntemleri kullanılarak birleştirilir. Yeni popülasyonda yer alacak bir kromozomun oluşturulma adımları aşağıdaki şekildedir.


1. Seçim operatörü yardımıyla iki kromozom (Ebeveyn 1 ve Ebeveyn 2) çaprazlama işlemine tabi tutulmak üzere seçilir.
2. Seçilen Ebeveyn 1 ve Ebeveyn 2 belirlenen çaprazlama yöntemine göre çaprazlama işlemine tabi tutulur.
3. Çaprazlama işleminden sonra eğer tek bir yavru birey elde edilmiş ise bu birey bir sonraki popülasyona hiçbir değerlendirme işlemine tabi tutulmadan aktarılır. Eğer iki yavru birey elde edilmiş ise uygunluk değeri daha yüksek olan yavru birey bir sonraki popülasyona aktarılır.

Bu işlem adımları yeni popülasyonun kromozom sayısı tamamlanana kadar tekrarlanır. Çaprazlama operatöründe kullanılmak üzere seçilen kromozomların uygunluk değerleri bulundukları popülasyondaki kromozomların uygunluk değerlerinden nispeten daha yüksek olduğundan, yeni üretilen kromozomların en iyi çözüme daha yakın olma olasılıkları yüksektir.

Çaprazlama işlemi gerçekleştirilirken çözülmesi amaçlanan probleme göre tek noktalı çaprazlama, çok noktalı çaprazlama ve düzgün çaprazlama olmak üzere farklı çaprazlama yöntemlerinden faydalanılabilir.

Tek Noktalı Çaprazlama


Tek noktalı çaprazlama yöntemi uygulaması oldukça kolay ve sık tercih edilen bir çaprazlama yöntemidir. Tek noktalı çaprazlama yönteminde ebeveynlerin genlerinin birleştirileceği tek bir nokta (G_1) vardır. Bu nokta çaprazlanacak kromozomların boyutuna bağlı olarak rastgele belirlenir. Ebeveyn 1'in G_1 noktasının solunda kalan genleri sabit tutulup, sağına Ebeveyn 2'nin G_1 noktasının sağında kalan genleri yerleştirilerek Yavru 1 oluşturulmuş olur. Ebeveyn 2'nin G_1 noktasının solunda kalan genleri sabit tutulup, sağına Ebeveyn 1'in G_1 noktasının sağında kalan genleri yerleştirilerek Yavru 2 oluşturulur. Oluşturulan bu iki yavru bireyin uygunlukları değerlendirilerek uygunluk değeri daha yüksek olan kromozom sonraki popülasyona aktarılır. Şekil 2.11'de tek noktalı çaprazlama yönteminin uygulanması görülmektedir.



Şekil 2.11. Tek noktalı çaprazlama

Çok Noktalı Çaprazlama


Çok noktalı çaprazlama yöntemi, tek noktalı çaprazlama yöntemine kıyasla daha karmaşık bir yöntemidir. Daha karmaşık olmasına rağmen oldukça sık tercih edilir. Çok noktalı çaprazlama yönteminde ebeveynlerin genlerinin birleştirileceği birden fazla çaprazlama noktası ($G_1, G_2, \dots, G_N$) vardır. Bu noktalar çaprazlanacak kromozomların boyutuna bağlı olarak rastgele belirlenir. Ebeveynlerin genlerinin G_1 ve G_2 olmak üzere iki noktadan çaprazlanacağını varsayalım. Bu durumda Şekil 2.12’de de görüldüğü gibi Ebeveyn 1’in G_1 noktasının solunda ve G_2 noktasının sağında kalan genleri sabit tutulup bu iki nokta arasında kalan genlerin Ebeveyn 2’nin G_1 ve G_2 noktaları arasında kalan genleri ile değiştirilmesi sonucu Yavru 1 oluşturulmuş olur. Ebeveyn 2’nin G_1 ve G_2 noktaları arasında kalan genleri sabit tutulup, Ebeveyn 1’in G_1 noktasının solunda ve G_2 noktasının sağında kalan genlerinin Ebeveyn 2’nin aynı genleri ile yer değiştirmesi ile Yavru 2 oluşturulmuş olur. Oluşturulan bu iki yavru bireyin uygunlukları değerlendirilerek uygunluk değeri daha yüksek olan kromozomun sonraki popülasyona aktarılması ile çok noktalı çaprazlama işlemi gerçekleştirilmiş olur.



Şekil 2.12. Çok noktalı çaprazlama

Düzgün Çaprazlama

Düzgün çaprazlamada sonraki popülasyona aktarılacak kromozomun genleri Ebeveyn 1 ve Ebeveyn 2'den belirli bir olasılıkla seçilerek oluşturulur. Şekil 2.13'te genlerin ebeveynlerden seçilme olasılıklarının eşit olduğu düzgün çaprazlama işlemi görülmektedir. İlgili gen için $[0, 1)$ arasında rastgele oluşturulan r değeri 0.5'ten küçükse o gen Ebeveyn 1'den 0.5'e eşit ya da 0.5'ten büyükse Ebeveyn 2'den seçilir.



Şekil 2.13. Düzgün çaprazlama

2.4.1.1.3 Mutasyon

Mutasyon işlemi seçim ve çaprazlama operatörleri kullanılarak oluşturulan popülasyonun içinden seçilen rastgele bir kromozomuna ya da rastgele seçilen bir kromozomun rastgele seçilen bir genine rastgele değer/değerler atanması işlemidir. Yapılan bu değişiklik çok küçük bir oranda gerçekleştirilir. Kromozomların genlerinde yapılan bu küçük değişiklikler ile popülasyon içinde çeşitlilik sağlanmış olur. Ayrıca genetik algoritmanın

çalışma uzayında arama sürecinin yerel optimum çözüme takılmasını önleyerek genel optimum çözüme yakınsaması sağlanmış olur.

Literatürde kullanılan pek çok mutasyon yöntemi vardır. Bu yöntemlerden en sık kullanılanları gen düzeyinde mutasyon, düzgün mutasyon, düzgün olmayan mutasyon ve anakromozomal mutasyon yöntemleridir.

Gen Düzeyinde Mutasyon

Bir popülasyonda rastgele seçilen bir kromozomun rastgele seçilen bir genine rastgele bir değer atanması ya da değer çıkarılması işlemidir.

Düzgün Mutasyon

Bir popülasyonda rastgele belirlenen bir kromozomun her geni için aynı olasılıkla mutasyon gerçekleştirilmesi işlemidir.

Düzgün Olmayan Mutasyon

Bir popülasyonda gerçekleştirilecek mutasyon oranının zaman içinde değiştiği mutasyon yöntemidir. Başlangıçta mutasyon oranı yüksektir. Her iterasyonda mutasyon oranı düşürülerek uygulanmaya devam edilir.

Anakromozomal Mutasyon

Anakromozomal mutasyon, bir kromozomun genlerinin tamamı belirli bir olasılıkla rastgele değiştirilir. Kromozomun tamamı, yeni gen değerlerine sahip olabilir.

2.4.1.1.4 Elitizm (Seçkinlik)

Genetik algoritmada elitizm önceden belirlenen elitizm oranına göre popülasyondaki en iyi kromozomun/kromozomların doğrudan bir sonraki popülasyona aktarılması işlemidir. Bu yolla yüksek performanslı çözümlerin korunması ve gelecek popülasyonlara aktarılması sağlanır. En iyi kromozomların genleri her nesilde korunduğu için algoritmanın performansının giderek artması beklenir. Ancak genetik algoritmada aşırı elitizm işlemi, popülasyon içindeki genetik çeşitliliği azaltıp çözüm uzayının daha dar bir alanında kalmasına sebep olabileceğinden elitizm oranı oldukça küçük bir değer olarak ayarlanır.

2.4.2. Binary Genetik Algoritma ile Öznitelik Seçme

Öznitelik seçme, büyük veriler ile gerçekleştirilen çalışmalarda karşılaşılan verinin işlenmesindeki zorlukları, işlem süresinin uzunluğu, maliyeti gibi problemleri ortadan kaldırmak için kullanılan bir yöntemdir. Öznitelik seçme yöntemi çeşitli algoritmalarından faydalanarak bir veri setindeki bilgilendirme açısından zayıf öznitelikleri eleyip, sınıflandırma üzerinde etkili en iyi öznitelikleri seçerek büyük veriler ile çalışmamıza olanak tanır. Genetik algoritma ile öznitelik seçme yönteminde ise en iyi öznitelikler seçim, çaprazlama ve mutasyon operatörlerinden faydalanılarak seçilir. Böylece daha az öznitelikle aynı ya da daha yüksek sınıflandırma doğruluğu elde edilmesi amaçlanır.

Bu tez çalışmasında, veri setlerinin öznitelik boyutunu küçültmek için öznitelik çıkarma ve öznitelik sıralama aşamalarında elde edilen tüm veri setlerine ayrı ayrı ikili (binary) genetik algoritma yöntemi ile öznitelik seçme işlemi uygulanmıştır. İkili genetik algoritma yöntemi ile öznitelik seçme işleminin uygulama adımları aşağıda detaylı olarak açıklanmıştır [40], [41].

1) Başlangıç parametrelerinin ayarlanması

Genetik algoritma ile öznitelik seçme yönteminin uygulanabilmesi için ilk olarak başlangıç popülasyonu oluşturulmalıdır. Başlangıç popülasyonunun oluşturulabilmesi için ise başlangıç parametreleri belirlenmelidir. Başlangıç parametreleri popülasyondaki kromozom sayısı, bir kromozomdaki öznitelik sayısı, maksimum iterasyon sayısı ve seçilecek öznitelik sayısıdır.

Bu tez çalışmasında optimum başlangıç parametresi değerleri denemeler sonucu belirlenmiştir. Bu değerler farklı oranlarda değiştirilerek deneyler gerçekleştirilmiştir. Gerçekleştirilen deneyler sonucu en iyi sonucu veren değerler saptanmıştır. Her veri seti için kromozom sayısı 50, maksimum iterasyon sayısı 200 ve seçilecek öznitelik sayısı ilgili veri kümesindeki öznitelik sayısının %10'u olarak belirlenmiştir. Bunlara ek olarak her bir kromozomdaki gen sayısı ilgili veri setinin öznitelik sayısı olarak ayarlanmıştır.

2) Başlangıç Popülasyonunun Oluşturulması

İkili genetik algoritma ile öznitelik seçebilmek için ilk olarak başlangıç popülasyonundaki kromozomlar oluşturulmalıdır. Bunun için başlangıç popülasyonu

oluşturulurken ilgili veri setinin öznitelik sayısı ile aynı boyuta sahip 50 adet kromozom oluşturulmuştur. Oluşturulan kromozomların gen sayısı ilgili veri setinde bulunan vektörlerin öznitelik sayısı ile aynıdır ve kromozomların n. geni ilgili veri setindeki n. özneliği temsil eder. Bu özneliklerin seçilip seçilmediği ise ilgili genin aldığı değere göre belirlenir. Bir kromozomun n. geninin değeri 1 ise veri setindeki n. özneliğin seçildiği, 0 ise n. özneliğin seçilmediği anlamına gelir. Oluşturulan kromozomlardaki genlerden %10'u rastgele seçilir. Seçilen bu genlere 1 değeri atanır. Seçilmeyen genler ise 0 değerini alır. Böylece başlangıç popülasyonu oluşturulmuş olur.

Örnek olarak Şekil 2.14'te Veriseti-1 için AlexNet sinir ağı ve iki örneklemli z-test yöntemi kullanılarak elde edilmiş 3651 adet öznitelik içeren veri setine, öznelik seçme yöntemi uygulamak için oluşturulmuş başlangıç popülasyonu görülmektedir. Şekilde de görüldüğü gibi 1. kromozomun 2. geni 0 değerini almış olup bu veri setindeki 2. özneliğin seçilmediği anlamına gelir. Örnek kromozomun 5. geni ise 1 değeri almış olup bu veri setindeki 5. özneliğin seçildiği anlamına gelir.

BAŞLANGIÇ POPÜLASYONU

	Gen 1	Gen 2	Gen 3	Gen 4	Gen 5	Gen 6	...	Gen 3646	Gen 3647	Gen 3648	Gen 3649	Gen 3650	Gen 3651
Kromozom 1	0	0	1	0	1	1	...	0	1	0	0	1	0
		↓ 2. öznelik seçilmemiş			↓ 5. öznelik seçilmiş								
Kromozom 2	0	1	1	0	0	1	...	0	0	0	0	0	1
Kromozom 3	1	1	1	0	0	1	...	1	1	0	0	0	0
Kromozom 4	0	0	1	0	1	1	...	0	1	0	0	1	0
...							...						
Kromozom 50	1	0	0	0	1	1	...	0	0	0	0	1	1

Şekil 2.14. Başlangıç popülasyonu

3) Uygunluk değerlerinin belirlenmesi

Başlangıç popülasyonu için oluşturulan her bir kromozomun uygunluk değeri 4-katlı çapraz doğrulama yöntemi ile KNN (K-En Yakın Komşu), SVM (Destek Vektör Makineleri) sınıflandırıcıları kullanılarak sınıflandırılmıştır. 4-katlı doğrulama yönteminin uygulama aşamaları, KNN ve SVM sınıflandırma yöntemleri ile uygunluk değeri hesaplama işlemleri Bölüm 2.6.'da detaylı olarak açıklanmıştır.

Kromozomların uygunluk değerleri hesaplandıktan sonra başlangıçta belirlenen durma kriterlerinin sağlanıp sağlanmadığı kontrol edilir. Durma kriteri herhangi bir kromozomun uygunluk değerinin belli bir değere eşit ya da bu değer üstünde olması olabileceği gibi arama yapılacak maksimum iterasyon sayısı da olabilir. Oluşturulan herhangi bir kromozom belirlenen durma kriterlerinden en az birini sağlarsa en uygun kromozom belirlenmiş olur. Durma kriterlerinin sağlanmadığı durumda bir sonraki popülasyon genetik algoritmanın operatörlerinden faydalanılarak oluşturulur. Bu tez çalışmasında belirlenen durma kriteri maksimum iterasyon sayısının 200 olmasıdır.

4) Genetik algoritma ile bir sonraki popülasyonun oluşturulması

Genetik algoritma ile öznitelik seçme işlemi için bir sonraki popülasyon oluşturulurken başlangıç popülasyonunda oluşturulan kromozomlar sırasıyla seçim, çaprazlama ve mutasyon operatörlerinden geçer. Bu operatörlerde gerçekleştirilen işlemler aşağıdaki şekildedir.

Seçim

Seçim aşamasında, yeni popülasyondaki bir kromozomu üretmek için başlangıç popülasyonundan iki kromozom rulet yöntemi kullanılarak seçilmiştir. Seçilen kromozomlar çaprazlanmak üzere çaprazlama operatörüne aktarılmıştır. Bu işlem yeni popülasyonda bulunacak 49 kromozom için tekrarlanmıştır. Ayrıca yüksek performanslı kromozomların korunmasını ve gelecek popülasyonlara aktarılmasını sağlamak için başlangıç popülasyondaki en iyi kromozom doğrudan bir sonraki popülasyona aktarılmıştır. Bu yüzden yeni popülasyondaki 50. kromozom başlangıç popülasyonundaki en iyi kromozomdur.

Çaprazlama

Seçim operatöründe seçilen kromozomlar düzgün çaprazlama yöntemi kullanılarak birbiri ile çaprazlanmıştır. Çaprazlama sonucunda bir önceki kromozomların genlerinden oluşan yeni kromozomlar elde edilmiştir. Elde edilen kromozomlar mutasyon operatörüne aktarılmıştır.

Mutasyon

Çaprazlama işleminden sonra elde edilen yavru bireyler gerekenden daha fazla veya daha az 1 değerine sahip olabilmektedir. Bu nedenle mutasyon aşamasında;

- Oluşturulan yeni kromozomlarda gerekenden fazla 1 değeri varsa fazla olan bu değerler rastgele seçilerek 0 değerine ayarlanmıştır.
- Oluşturulan yeni kromozomlarda gerekenden daha az 1 değeri varsa kromozomların 0 olan fazla değerleri rastgele seçilerek 1 değerine ayarlanmıştır.

Böylece seçilen özellik sayısı her zaman ilgili veri setindeki özellik sayısının %10'una eşittir.

Yeni kromozomlar üretildikten sonra işlem 3. adıma dönerek yeni oluşturulmuş kromozomların uygunluk değerleri hesaplanır. Bu adımlar maksimum iterasyon sayısına ulaşıncaya kadar tekrarlanır. Maksimum iterasyon sayısına ulaşıldığında en yüksek uygunluk değerini veren kromozom belirlenir. En uygun kromozomun 1 değerine sahip genleri, ilgili veri setindeki sınıflandırmada etkili en iyi özelliklere karşılık gelir.

Tüm sayısal veri setleri için ikili genetik algoritma yöntemi ile özellik seçme aşamasında elde edilen öznitelik sayıları ve özniteliklerin azalma oranları Tablo 2.2'nin IV numaralı sütununda görülmektedir. Ayrıca öznitelik çıkarma aşamasında elde edilen öznitelik vektörlerine öznitelik sıralama yöntemi uygulanmadan sadece öznitelik seçme yöntemi uygulanması ile elde edilen öznitelik sayıları Tablo 2.2'nin III numaralı sütununda görülmektedir.

2.5. Sınıflandırma

Sınıflandırma, bir veri setindeki sınıfı bilinmeyen örneklerin, önceden tanımlanmış örneklerin özellikleri ve sınıflarından faydalanılarak sınıflandırılması işlemidir. Pek çok sınıflandırma yöntemi vardır. Özellikle makineli öğrenme ve derin öğrenme yöntemleri verilerin bilgisayarlar aracılığıyla sınıflandırılmasında kullanılan etkin sınıflandırma yöntemlerindendir.

Bu tez çalışmasında öznitelik seçme aşamasında elde edilen veri setlerinin uygunluğu 4-katlı çapraz doğrulama ile K-En Yakın Komşu (KNN) ve Destek Vektör Makineleri (SVM) makineli öğrenme yöntemlerinden faydalanılarak sınıflandırılmıştır. Aşağıda 4-katlı çapraz doğrulama yönteminin uygulama aşamaları, KNN ve SVM sınıflandırma yöntemleri ile uygunluk değeri hesaplama işlemleri detaylı olarak açıklanmıştır.

2.5.1. Doğrulama Teknikleri

Doğrulama teknikleri sınıflandırma ve regresyon işlemi için kullanılan makineli öğrenme algoritmalarının mevcut veriyi ne kadar iyi öğrendiğini ve genelleştirilebildiğini değerlendirmek için kullanılır. Test seti yöntemi, LOOCV yöntemi, N-katlı çapraz doğrulama gibi pek çok doğrulama tekniği vardır. Bu doğrulama tekniklerinin detayları aşağıdaki şekildedir [42].

2.5.1.1. Test Seti Yöntemi (Holdout)

Test seti yönteminde bir veri setindeki sınıfı bilinen veriler eğitim ve test veri seti olarak belirli bir oranda ayrılır. Bu oran genellikle %70 eğitim, %30 test şeklindedir. Eğitim seti makineli öğrenme algoritmalarını eğitmek için kullanılır. Bu eğitim sırasında makineli öğrenme algoritmaları veri setinin sınıfları arasındaki farkları belirleyerek sınır çizgileri oluşturur. Eğitim işlemi tamamlandığında algoritmaların doğruluğu, test seti olarak ayrılan ve algoritmanın daha önce hiç görmediği veriler kullanılarak test edilir.

2.5.1.2. LOOCV yöntemi (Leave-One-Out Cross Validation)


LOOCV yönteminde, veri setindeki bir örnek dışarıda bırakılır ve geriye kalan örneklerle makineli öğrenme algoritmaları eğitilir. Eğitim işleminden sonra algoritmaların doğruluğu dışarıda bırakılan örnek kullanılarak değerlendirilir. Bu işlem veri setindeki

bütün örnekler için gerçekleştirilir. LOOCV yöntemi genellikle çalışılan verilerin sınırlı olduğu veri setlerinde kullanılır. Böylelikle veri kaybı yaşanmadan doğrulama işlemi gerçekleştirilmiş olur.

2.5.1.3. N-Katlı Çapraz Doğrulama (N-Fold Cross Validation)

N-katlı çapraz doğrulama işleminde bir veri setindeki örnekler eşit sayıda rastgele ayrılarak gruplandırılır. Eğer örnekler 4 eşit gruba ayrılırsa 4-katlı çapraz doğrulama, 5 eşit gruba ayrılırsa 5-katlı çapraz doğrulama vs. olarak adlandırılır. Ayrılan gruplar algoritmaları test etmek için sırasıyla test verisi olarak, geriye kalan gruplar ise algoritmaları eğitmek için eğitim verisi olarak ayarlanır. Böylelikle kullanılan algoritmanın uygunluğu değerlendirilmiş olur.

Bu tez çalışmasında 4-katlı çapraz doğrulama işleminden faydalanılarak kullanılan yöntemlerin uygunlukları değerlendirilmiştir. Şekil 2.15'te 4-katlı çapraz doğrulama işleminin uygulama adımları görülmektedir. İlk olarak veri setleri rastgele seçilmiş örneklerden oluşan 4 eşit gruba ayrılmıştır. Daha sonra her adımda farklı bir grup test verisi, geriye kalan gruplar eğitim verisi olarak seçilmiştir. KNN ve SVM algoritmaları her adımda seçilen eğitim verileri kullanılarak eğitilmiş ve test verileri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 2.15. 4-Katlı çapraz doğrulama işlemi

2.5.2. Makineli Öğrenme Yöntemleri ile Sınıflandırma

Makineli öğrenme, çeşitli algoritmalarla faydalanarak verilerin bilgisayarlar aracılığıyla sınıflandırılmasını ya da kümeleneşini sağlayan yapay zekâ yaklaşımıdır. Makineli öğrenme yöntemlerinde kullanılan algoritmalar mevcut verilerin özelliklerini detaylı olarak inceleyerek gözle görülmeyen ilişkileri tespit eder. Böylelikle mevcut verilerin özelliklerinden ve kategorilerinden faydalanarak yeni verilerin ait olduğu sınıf ya da küme yüksek doğrulukla belirlenebilir. Takviyeli öğrenme, denetimsiz öğrenme ve denetimli öğrenme olmak üzere üç farklı makineli öğrenme yöntemi mevcuttur. Bu öğrenme yöntemlerinin detayları aşağıdaki şekildedir [43].

Takviyeli Öğrenme

Takviyeli öğrenmede verilerin uygunluğu bir ödül-ceza sistemi ile değerlendirilir. Çalışma uzayında belli bir noktada olan test verilerinin optimum noktaya ulaşmak için gerçekleştirdiği eylemler optimuma yaklaşma şeklinde ise ödüllendirme, uzaklaşma şeklinde ise cezalandırma olarak değerlendirilir. Her bir test verisi en yüksek puanı alarak optimuma daha çok yaklaşmayı amaçlar. Bu yolla çevresi ile etkileşimlere bağlı ve iyileştirmeye dayalı bir sistem geliştirilmiş olur.

Denetimsiz Öğrenme

Denetimsiz öğrenmede sınıflandırılmış veriler yoktur. Çeşitli algoritmalarla faydalanılarak sınıfı belli olmayan veriler arasındaki örüntüler belirlenir. Bu örüntülerden faydalanılarak aynı küme içerisinde yer alan veriler belirlenir. Kümeleme ve boyut azaltma yöntemleri sık kullanılan denetimsiz öğrenme yöntemlerindendir.

Denetimli Öğrenme

Denetimli öğrenmede, algoritmalarla veriler sınıf etiketi ile birlikte verilir. Algoritmalar verilerin özellikleri ile sınıf etiketi arasındaki ilişkiyi çeşitli yaklaşımlar kullanarak öğrenir. Bu öğrenme işlemi için yeterince sınıfı bilinen veri gereklidir. Veriler ile sınıfları arasındaki ilişkiyi öğrenen algoritmalar sınıfı bilinmeyen yeni bir veriyi özelliklerinden faydalanarak yüksek doğrulukla sınıflandırabilir.

Denetimli öğrenmede çözülmek istenen probleme göre kullanılan algoritmaların türü değişir. Çözülmek istenen probleme ait veri setinin sonuç çıktısı kategorik ise sınıflandırma algoritmalarından, sürekli ise regresyona dayalı algoritmalarından faydalanılır. Regresyona dayalı algoritmalarla Doğrusal Regresyon (LR), Lojistik Regresyon örnek verilebilir. Sınıflandırma için kullanılan algoritmalarla ise K-En Yakın Komşu (KNN) algoritması, Destek Vektör Makineleri (SVM), Naive-Bayes algoritması, Karar Ağaçları (DT) örnek verilebilir.

2.5.2.1. K-En Yakın Komşu Algoritması (K-Nearest Neighbor - KNN)

K-en yakın komşu algoritması (KNN) uygulanması kolay, gürültüye karşı toleranslı ve hızlı sonuca giden bir sınıflandırma algoritmasıdır. Bu algoritma, sınıfı bilinmeyen verileri özellikleri ve sınıf etiketi bilinen verilerden faydalanarak önceden belirlenen örnek sayısı dâhilinde en yakın mesafedeki sayıca baskın sınıfa dâhil eder. KNN algoritmasının uygulama aşamaları aşağıdaki şekildedir [44], [45].

- 1) İlk olarak bir veri setindeki sınıfı bilinen veriler sahip oldukları özniteliklerin değerlerine göre bir düzlemde konumlanır. Bu düzlemin boyutu verilerin öznitelik sayısına eşittir.
- 2) Daha sonra sınıfı bilinmeyen bir test verisi sınıfı belirlenmek üzere öznitelik değerlerinden faydalanılarak aynı düzleme yerleştirilir. Yerleştirilen bu test verisi ile sınıfı bilinen veriler arasındaki mesafeler hesaplanır. Veriler arasındaki mesafeleri hesaplamak için Öklid mesafesi, Manhattan mesafesi, Kosinüs mesafesi, Minkowski mesafesi gibi pek çok yöntem vardır. Bu yöntemlerin formülleri Tablo 2.6'da görülmektedir. Burada x ve y aralarındaki mesafenin hesaplanacağı noktaları, n ise aralarındaki mesafelerin hesaplanacağı nokta çiftlerinin sayısını göstermektedir.


Tablo 2.6. Mesafe hesaplama yöntemleri ve formülleri

Yöntem	Formül
Öklid Mesafesi	$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$ (2.4)
Manhattan Mesafesi	$D(x, y) = \sum_{i=1}^n (x_i - y_i)$ (2.5)
Kosinüs Mesafesi	$D(x, y) = \frac{x \cdot y}{\ x\ \ y\ }$ (2.6)
Minkowski Mesafesi	$D(x, y) = (\sum_{i=1}^n x_i - y_i ^p)^{1/p}$ (2.7)

Test verisi ile sınıfı bilinen veriler arasındaki mesafeler hesaplandıktan sonra bu mesafeler küçükten büyüğe doğru sıralanır.

- 3) Test verisi ile sınıfı bilinen veriler arasındaki mesafeler belirlenip sıralandıktan sonra bir **k** sabiti belirlenir. **k** sabiti bir test verisinin dahil edileceği sınıfın belirlenmesinde önemli bir parametredir. **k** sabitinin değerine göre test verisinin dahil edileceği sınıf değişiklik gösterebilmektedir. Bu yüzden **k** sabiti en uygun şekilde belirlenmelidir. En uygun **k** değeri aşırı öğrenme (overfitting) ile eksik öğrenme (underfitting) arasında denge kurularak belirlenmelidir. Ayrıca **k** sabitinin değeri 1 alındığında test verisi sadece en yakınındaki sınıfa dâhil olur. Bu durum algoritmanın doğruluğunu düşürebilir. Çift alındığında ise her sınıfın eşit sayıda örneğine yakın olabilmektedir. Bu durumda da test verisinin hangi sınıfa dâhil edileceği kesin bir şekilde belirlenemez. Bu yüzden **k** sabiti genelde 1 hariç tek sayı seçilmektedir. Bazı akademik çalışmalar ise en uygun **k** değerinin, test verisinin sınıfını belirlemek için kullanılan sınıfı bilinen verilerin sayısının karekökü alınarak belirlenebileceğini önermektedir [44].
- 4) **k** sabiti belirlendikten sonra sıralanan mesafe değerleri değerlendirilir. Test verisine en yakın **k** sabiti kadar verinin sınıfı incelenir. Bu veriler en çok hangi sınıfa ait ise test verisi o sınıfa dâhil edilir. Böylelikle sınıfı bilinmeyen bir veri sınıflandırılmış olur.

Şekil 2.16’da sınıfı bilinmeyen bir test verisinin KNN algoritması ile sınıflandırılması görülmektedir. Şekilde bir veri setindeki iki sınıflı veriler ve sınıfı bilinmeyen test verisi yükseklik ve genişlik öznelik değerlerine göre iki boyutlu düzleme yerleştirilmiştir. k sabiti 3 olarak kabul edildiğinde test verisine en yakın 3 verinin ikisinin Sınıf 1’e birinin ise Sınıf 2’ye dahil olduğu görülmektedir. Bu durumda test verisi Sınıf 1’e dâhil edilmiştir.



Şekil 2.16. KNN algoritmasının sınıflandırma mekanizması


Bu tez çalışmasında KNN ile gerçekleştirilen sınıflandırma işlemlerinde k değeri gerçekleştirilen optimizasyon çalışmaları sonucu 3 olarak belirlenmiştir.

2.5.2.2. Destek Vektör Makineleri Algoritması (Support Vector Machine - SVM)

Destek vektör makineleri (SVM) sınıflandırma ve regresyon problemlerinde oldukça iyi sonuçlar vermesinden dolayı geniş çapta benimsenmiş bir sınıflandırma algoritmasıdır. Bir veri setindeki verilerin sınıflarını en uygun şekilde ayırmak için bir boyutlu uzayda nokta, iki boyutlu uzayda bir doğru çizilerek, çok boyutlu uzayda düzlem oluşturarak sınıflar birbirinden ayrılır. Oluşturulan bu sınıra hiper düzlem denir. Sınıfı bilinmeyen bir örneğin sınıfı, örneğin veri uzayındaki konumuna göre oluşturulan bu hiper düzlemde

faaydalanılarak belirlenir. İki sınıflı bir veri seti için SVM algoritmasının uygulama aşamaları aşağıdaki şekildedir [46, 47].

- 1) İlk olarak veri setindeki sınıfı bilinen veriler sahip oldukları özniteliklerin değerlerine göre bir düzlemde konumlanır. Bu düzlemin boyutu veri setindeki sınıf sayısına eşittir.
- 2) SVM’de hiper düzlem ile en yakın veri noktası arasında kalan uzunluğun sınıfların birbirinden daha iyi ayrılması için olabildiğince büyük olması istenir [47]. Şekil 2.17’de d ile gösterilen bu uzunluk margin (kenar payı) olarak adlandırılmaktadır. ‘ d ’ uzunluğu hiper düzleme en yakın veri noktalarına göre belirlenmektedir. Bu verilere ‘destek vektörleri’ denilmektedir. Hiper düzlemi oluşturmak için destek vektörleri Şekil 2.17.’de görüldüğü gibi çember içine alınır. Sınıfları birbirinden ayırmak için birbirine paralel ve destek vektörleri üzerinden geçen H_1 ve H_2 ile gösterilen yardımcı hiper düzlemler oluşturulur.



Şekil 2.17. Hiper düzlemin oluşturulması

- 3) En uygun hiper düzlemin oluşturulmasında yardımcı hiper düzlemlerin birbirine olan uzaklığın en büyük olması istendiği için hiper düzlem olarak H vektörü belirlenir. Böylelikle iki sınıflı verileri sınıflandırmak için bir hiper düzlem oluşturulmuş olur.

- 4) Hiper düzlem oluşturulduktan sonra sınıfı bilinmeyen bir veri, veri uzayına yerleştirilir. Hiper düzleme göre bulunduğu bölge hangi sınıfın verilerine aitse o sınıfa dahil edilir.

Sınıfı bilinmeyen örnekler SVM algoritması kullanılarak bu şekilde sınıflandırılır.

Bu tez çalışmasında öznelik seçme aşamasında elde edilen veri setlerinin KNN ve SVM sınıflandırıcıları ile sınıflandırılması sonucu karışıklık matrisleri elde (Confusion Matrix) elde edilmiştir. Öznelik seçme aşamasında elde edilen boyutu azaltılmış veri setlerinin tıbbi görüntüleri temsil etmedeki uygunluğu elde edilen bu karışıklık matrislerinden ve performans metriklerinden faydalanılarak değerlendirilmiştir. Karışıklık matrislerinin nasıl elde edildiği, performans metriklerinin formülleri aşağıda detaylı olarak açıklanmıştır.

2.5.3 Performans Metrikleri

Verilerin sınıflandırma yöntemleriyle sınıflandırılması sonucu bir karışıklık matrisi (Confusion Matrix) elde edilir. Karışıklık matrisi, sınıflandırılan verilerden kaç tanesinin sınıflandırıcı tarafından doğru, kaç tanesinin yanlış sınıflandırıldığını gösteren bir tablodur. Tablo 2.7.'de 2 sınıflı veri seti için oluşturulmuş örnek bir karışıklık matrisi görülmektedir. Matris elemanlarının tanımları aşağıdaki şekildedir [48];

Tablo 2.7 Örnek bir karışıklık matrisi

	TAHMİN		
GERÇEK		1	0
	1	DP	YN
	0	YP	DN

- DP, Doğru Pozitif - Sınıf etiketi 1 olan ve sınıflandırıcı tarafından sınıf etiketi 1 olarak tahmin edilen örnek sayısı.
- DN, Doğru Negatif - Sınıf etiketi 0 olan ve sınıflandırıcı tarafından sınıf etiketi 0 olarak tahmin edilen örnek sayısı.
- YN, Yanlış Negatif - Sınıf etiketi 1 olan ve sınıflandırıcı tarafından sınıf etiketi 0 olarak tahmin edilen örnek sayısı.
- YP, Yanlış Pozitif - Sınıf etiketi 0 olan ve sınıflandırıcı tarafından sınıf etiketi 1 olarak tahmin edilen örnek sayısı.

DP ve DN sınıflandırıcının doğru sınıflandırma sayısını, YP ve YN sınıflandırıcının yanlış sınıflandırma sayısını belirtmektedir. Doğru bir sınıflandırıcıdan elde edilen DP + DN değerlerinin, YP + YN değerlerinden çok daha yüksek olması beklenir. Toplam örnek sayısı ise $= DP + DN + YP + YN$ 'dir.

Tıbbi görüntülerin sınıflandırılmasında kullanılan yöntemlerin uygulanabilirliği, karışıklık matrislerinden faydalanılarak doğruluk, duyarlılık, özgüllük gibi metriklerin hesaplanmasıyla değerlendirilir.

Doğruluk (Accuracy): Sınıflandırıcıların test verilerinin yüzde kaçının doğru olarak sınıflandırıldığını belirten metriktir. Denklem 2.8'de görüldüğü gibi doğru sınıflandırılan veri sayısının toplam örnek sayısına bölünmesi ile hesaplanmaktadır.

$$Doğruluk = \frac{DP+DN}{DP + DN + YP + YN} \quad (2.8)$$

Duyarlılık (Sensitivity): Sınıflandırıcıların doğru olarak sınıflandırdığı pozitif örneklerin, gerçekte pozitif olan örneklerle oranıdır. Bu yüzden duyarlılık gerçek pozitif oranı olarak bilinmektedir. Denklem 2.9'da görüldüğü gibi hesaplanmaktadır.

$$Duyarlılık = \frac{DP}{DP+YN} \quad (2.9)$$

Özgüllük (Specificity): Sınıflandırıcıların doğru olarak sınıflandırdığı negatif örneklerin, gerçekte negatif olan örneklere oranıdır. Bu yüzden özgüllük gerçek negatif oranı olarak bilinmektedir. Denklem 2.10’da görüldüğü gibi hesaplanmaktadır.

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (2.10)$$

Bu metriklerin hesaplanması sonucu elde edilen değerler 1’e ne kadar yakınsa o yöntemin uygulanabilirliği o kadar yüksek demektir.

Sunulan yöntemin etkinliğini değerlendirmek için öznitelik çıkarma, öznitelik sıralama ve öznitelik seçme adımlarında elde edilen veri setleri 4-katlı çapraz doğrulama ile KNN ve SVM sınıflandırma yöntemleri kullanılarak sınıflandırılmıştır. Sınıflandırmalar sonucu 4 farklı karışıklık matrisi elde edilmiştir. Elde edilen her bir karışıklık matrisi için doğruluk, duyarlılık ve özgüllük değerleri elde edilmiştir. Nihai sınıflandırma sonuçlarını elde etmek için bu 4 farklı karışıklık matrisi kullanılarak elde edilen doğruluk, duyarlılık ve özgüllük değerleri ayrı ayrı toplanıp 4’e bölünmüştür. Sınıflandırma sonucu elde edilen doğruluk, duyarlılık ve özgüllük değerlerinden faydalanılarak sunulan yöntemin uygulanabilirliği ve etkinliği değerlendirilmiştir. Değerlendirmeler sonucu elde edilen sonuçlar Bölüm 3’te detaylı olarak sunulmuştur.

Bu çalışmada gerçekleştirilen deneyler Windows 11 işletim sistemine sahip, Ryzen 7 işlemcili, 16 GB RAM belleğe ve NVIDIA GeForce RTX 3080 Ti GPU ünitesine sahip bir bilgisayarda gerçekleştirilmiştir. Çalışmada kullanılan kodlar MATLAB 2023B kullanılarak geliştirilmiştir.

2.6. İstatistiksel Analiz

Bu tez çalışmasında öznitelik çıkarma, öznitelik sıralama ve öznitelik seçme işlemlerinin peş peşe uygulanmasını içeren yöntemin sinir ağları (AlexNet, ResNet-101 ve AlexNet + ResNet-101) ve sınıflandırma yöntemleri (KNN ve SVM) ile ilişkisini analiz etmek için istatistiksel analiz yöntemlerinden faydalanılmıştır. Merkezi limit teoremi (Central Limit Theorem - CLT) örneklem büyüklüğünün 30 ve 30'dan büyük olduğu durumlarda örneklem ortalamalarının dağılımının normal dağılıma yaklaşacağını belirttiğinden bu çalışmada gerçekleştirilen tüm deneyler 30 kez tekrarlanmıştır [49], [50]. İstatistiksel analiz KNN ve SVM makineli öğrenme yöntemlerinden elde edilen doğruluk değerleri üzerinde gerçekleştirilmiştir.

Normal dağılımın kontrolü için örneklem büyüklüğünün 50'den az olduğu durumlarda kullanılan ve normal dağılım analizinde genellikle oldukça iyi sonuçlar veren Shapiro Wilk testi kullanılmıştır [51]. Shapiro Wilk testine göre, sinir ağlarından elde edilen öznitelik vektörlerine sunulan yöntemin uygulanması ile elde edilen doğruluk değerlerinden **en az birinin** istatistiksel anlamlılık değerinin (p-değeri) 0,05'ten küçük olması, veri dağılımının normal dağılım sergilemediğini göstermektedir [52]. Veri dağılımının normal dağılım sergileyip sergilemediği değerlendirildikten sonra sinir ağlarından elde edilen öznitelik vektörlerine sunulan yöntemin uygulanması ile elde edilen doğruluk değerleri arasında anlamlı bir fark olup olmadığını araştırmak için parametrik ya da parametrik olmayan testlerden faydalanılır. Eğer verilerin hepsi normal dağılıma sahipse parametrik testler, verilerden en az biri normal dağılıma sahip değilse parametrik olmayan testler kullanılır.

Bu tez çalışmasında elde edilen doğruluk değerlerinden bazıları normal dağılım sergilemediğinden parametrik olmayan testlerden Kruskal-Wallis testi ve Mann-Whitney U testi [53] doğruluk değerleri arasında anlamlı bir fark olup olmadığını araştırmak için kullanılmıştır. Shapiro Wilk testi kullanılarak elde edilen normal dağılım analiz sonuçları Bölüm 3'te KNN sınıflandırıcısı ile gerçekleştirilen deneyler için Tablo 3.13.'de, SVM sınıflandırıcısı ile gerçekleştirilen deneyler için Tablo 3.16'da sunulmuştur.

Sinir ağlarından elde edilen öznitelik vektörlerine sunulan yöntemin uygulanması ile elde edilen doğruluk değerleri arasında anlamlı bir farklılığın olup olmadığını araştırmak amacıyla ilk olarak veri gruplarına Kruskal-Wallis testi uygulanmıştır. Anlamlılık

değerinin (p-değeri) 0,05'ten küçük olması, gruplar arasında dikkate değer bir fark olduğunu, 0,05'ten büyük olması ise gruplar arasında dikkate değer bir fark olmadığını göstermektedir. Gruplardan hangisinin istatistiksel olarak farklı olduğunu belirlemek amacıyla önce AlexNet ve ResNet-101'e, sonra AlexNet ve AlexNet + ResNet-101'e, son olarak ise ResNet-101 ve AlexNet + ResNet-101'e sunulan yöntemin uygulanması ile elde edilen doğruluk değerlerinden hangileri arasında anlamlı farklılıklar olduğunu araştırmak amacıyla iki bağımsız grup testi olan Mann-Whitney U testi kullanılmıştır. Mann-Whitney U testinin uygulanması sonucu elde edilen p-değerinin 0,05'ten küçük olması iki grup arasında istatistiksel olarak anlamlı bir fark olduğunu, 0,05'ten büyük olması ise iki grup arasında istatistiksel olarak anlamlı bir fark olmadığını göstermektedir [53]. Gruplara Kruskal-Wallis testi ve Mann-Whitney U testi uygulanması sonucu elde edilen sonuçlar Bölüm 3'te detaylı olarak sunulmuştur.

Bu çalışmada gerçekleştirilen bütün istatistiksel anlamlılık testleri SPSS ortamında gerçekleştirilmiştir.

3. BÖLÜM

DENEYSEL SONUÇLAR

3.1 Giriş

Bu tez çalışmasında kullanılan yöntemin (Bölüm 2) etkinliğini değerlendirmek amacı ile öznitelik çıkarma, öznitelik sıralama ve öznitelik seçime aşamalarında elde edilen her bir öznitelik vektörü KNN ve SVM sınıflandırıcıları kullanılarak sınıflandırılmıştır. Sınıflandırmalar sonucunda doğruluk, duyarlılık ve özgüllük değerleri elde edilmiştir. Tüm deneyler 4-katlı çapraz doğrulama kullanılarak 30 tekrarda gerçekleştirilmiştir.

Son olarak AlexNet, ResNet-101 ve AlexNet + ResNet-101'den elde edilen öznitelik vektörlerine bu tez çalışmasında sunulan yöntemin uygulanmasıyla elde edilen değerler arasında istatistiksel olarak anlamlı bir fark olup olmadığı KNN ve SVM sınıflandırma yöntemleriyle elde edilen doğruluk değerlerinden faydalanılarak değerlendirilmiştir. Bütün değerlendirmeler Veriseti-1, Veriseti-2 ve Veriseti-3 için ayrı ayrı gerçekleştirilmiştir. Elde edilen sonuçlar Bölüm 3.2'de detaylı olarak sunulmuştur.

3.2 Deneysel Sonuçlar

Öznitelik çıkarma aşamasında, AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağlarından elde edilen özellik vektörleri KNN ve SVM sınıflandırıcıları kullanılarak sınıflandırılmıştır. Sınıflandırmalar sonucu Veriseti-1, Veriseti-2 ve Veriseti-3 için elde edilen doğruluk, duyarlılık ve özgüllük değerleri sırasıyla Tablo 3.1, Tablo 3.2 ve Tablo 3.3'te görülmektedir.

Tablo 3.1 incelendiğinde öznitelik çıkarma adımı Veriseti-1 için KNN ve SVM algoritmaları ile gerçekleştirilen deneylerde en yüksek doğruluk değerlerinin sırasıyla %94,5 ve %98,2 olduğu ve AlexNet + ResNet-101 sinir ağlarından elde edildiği görülmektedir. Benzer şekilde Tablo 3.2 ve Tablo 3.3'teki Veriseti-2 ve Veriseti-3 için KNN ve SVM algoritmaları ile gerçekleştirilen deneylerden elde edilen doğruluk değerleri incelendiğinde en yüksek doğruluk değerlerinin Veriseti-2 için %88,5, Veriseti-3 için %86,0 olduğu ve AlexNet + ResNet-101 sinir ağlarından elde edildiği görülmüştür. Bu sonuçlar AlexNet ve ResNet-101 sinir ağlarının birleştirilmesi ile elde edilen özniteliklerin bu sinir ağlarının ayrı ayrı kullanılması ile elde edilen özniteliklerden daha fazla ayırt edici bilgi taşıdığını göstermiştir.

Tablo 3.1. Veriseti-1 için sinir ağlarından elde edilen öznitelik vektörlerinin sınıflandırma sonuçları

Uygunluk Değerleri		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	94,0 ± 0,9	95,1 ± 1,7	90,9 ± 1,0
	SVM	96,5 ± 1,1	96,7 ± 1,6	94,8 ± 1,8
ResNet-101	KNN	93,4 ± 1,1	95,7 ± 0,9	91,5 ± 1,5
	SVM	96,9 ± 1,3	97,0 ± 1,2	94,7 ± 0,9
AlexNet + ResNet-101	KNN	94,5 ± 0,9	96,2 ± 1,8	95,2 ± 1,4
	SVM	98,2 ± 0,9	98,6 ± 1,7	96,0 ± 1,0

Tablo 3.2. Veriseti-2 için sinir ağlarından elde edilen öz nitelik vektörlerinin sınıflandırma sonuçları

Uygunluk Değerleri		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	84,2 ± 2,1	76,8 ± 2,4	81,5 ± 1,1
	SVM	86,4 ± 2,0	79,9 ± 1,1	78,2 ± 1,1
ResNet-101	KNN	86,1 ± 1,7	79,6 ± 1,4	80,2 ± 1,5
	SVM	88,2 ± 1,4	84,7 ± 2,1	84,1 ± 1,7
AlexNet + ResNet-101	KNN	88,4 ± 1,7	83,2 ± 1,0	83,4 ± 1,2
	SVM	88,5 ± 1,9	84,6 ± 2,2	85,5 ± 1,3

Tablo 3.3. Veriseti-3 için sinir ağlarından elde edilen öz nitelik vektörlerinin sınıflandırma sonuçları

Uygunluk Değerleri		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	82,8 ± 1,4	86,2 ± 2,6	83,1 ± 1,4
	SVM	83,7 ± 1,2	83,6 ± 1,7	81,5 ± 1,1
ResNet-101	KNN	83,3 ± 1,5	83,4 ± 1,9	82,9 ± 2,1
	SVM	84,5 ± 2,2	86,9 ± 1,1	83,5 ± 1,4
AlexNet + ResNet-101	KNN	84,2 ± 1,0	84,2 ± 0,9	82,4 ± 1,4
	SVM	86,0 ± 1,1	86,3 ± 1,2	84,9 ± 1,2

Öz nitelik sıralama aşamasında, AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağlarından elde edilen özellik vektörlerinin boyutu iki örneklemlili z-testi yöntemi kullanılarak azaltılmış ve KNN ve SVM sınıflandırıcıları kullanılarak sınıflandırılmıştır. Sınıflandırmalar sonucu Veriseti-1, Veriseti-2 ve Veriseti-3 için elde edilen doğruluk,

duyarlılık ve özgüllük değerleri sırasıyla Tablo 3.4, Tablo 3.5 ve Tablo 3.6’da görülmektedir.

Tablo 3.4, Tablo 3.5 ve Tablo 3.6’da sunulan sonuçlar incelendiğinde en yüksek doğruluk değerlerinin Veriseti-1, Veriseti-2 ve Veriseti-3 için sırasıyla %98,0, %89,6 ve %86,2 olduğu ve AlexNet + ResNet-101 sinir ağlarından elde edildiği görülmüştür. Bu sonuçlar öznelite çıkarma adımında elde edilen en yüksek doğruluk değerleri ile kıyaslandığında sadece Veriseti-1 için %0,2 oranında küçük bir düşüş olduğu, Veriseti-2 ve Veriseti-3 için sırasıyla %1,1 ve %0,2 oranında artış olduğu görülmüştür. Bölüm 2 de sunulan Tablo 2,2’nin I ve II numaralı sütunları incelendiğinde ise öznelite sıralama işlemi ile öznelite sayılarının önemli miktarda azaldığı görülmektedir. Öznelite sayılarındaki bu azalmaya rağmen elde edilen doğruluk değerlerindeki artış iki örneklemlili z-testi yönteminin özneliteikleri azaltmada etkin bir yöntem olduğunu göstermiştir.

Tablo 3.4. Veriseti-1 için iki örneklemlili z-testi yöntemi kullanılarak elde edilen boyutu azaltılmış öznelite vektörlerinin sınıflandırma sonuçları

Uygunluk Değerleri		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	94,0 ± 1,2	96,7 ± 0,9	95,2 ± 1,2
	SVM	96,5 ± 1,1	97,1 ± 1,1	95,2 ± 1,7
ResNet-101	KNN	95,1 ± 0,9	96,2 ± 1,7	93,5 ± 2,1
	SVM	96,9 ± 1,2	97,3 ± 1,8	96,6 ± 2,0
AlexNet + ResNet-101	KNN	94,3 ± 1,3	96,8 ± 0,8	93,8 ± 1,9
	SVM	98,0 ± 0,9	98,1 ± 1,2	97,2 ± 1,7

Tablo 3.5. Veriseti-2 için iki örneklemlili z-testi yöntemi kullanılarak elde edilen boyutu azaltılmış öznelik vektörlerinin sınıflandırma sonuçları

		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	84,7 ± 1,4	76,7 ± 1,7	75,4 ± 1,6
	SVM	86,5 ± 2,1	80,0 ± 2,0	82,5 ± 2,2
ResNet-101	KNN	88,4 ± 1,7	83,9 ± 1,2	84,6 ± 1,9
	SVM	86,7 ± 1,3	81,1 ± 1,4	78,2 ± 1,3
AlexNet + ResNet-101	KNN	89,5 ± 1,1	85,6 ± 0,9	87,5 ± 1,2
	SVM	89,6 ± 2,1	86,6 ± 1,9	88,9 ± 1,8

Tablo 3.6. Veriseti-3 için iki örneklemlili z-testi yöntemi kullanılarak elde edilen boyutu azaltılmış öznelik vektörlerinin sınıflandırma sonuçları

Uygunluk Değerleri		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	83,3 ± 2,0	86,2 ± 1,7	84,7 ± 1,4
	SVM	84,1 ± 1,7	82,5 ± 1,5	81,4 ± 1,2
ResNet-101	KNN	82,8 ± 2,4	83,7 ± 2,1	82,5 ± 1,1
	SVM	83,2 ± 1,2	83,4 ± 0,9	81,4 ± 0,9
AlexNet + ResNet-101	KNN	84,0 ± 1,4	86,0 ± 1,2	83,2 ± 1,2
	SVM	86,2 ± 2,0	86,9 ± 1,1	86,3 ± 1,4

Öznelik seçme aşamasında, AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağlarından elde edilen özellik vektörlerine iki örneklemlili z test yönteminin uygulanması ile elde edilen boyutu azaltılmış vektörlere BGA yöntemi ile öznelik seçme yöntemi uygulanmıştır. BGA yönteminin uygulanması ile elde edilen en iyi öznelikler KNN ve

SVM yöntemleri ile sınıflandırılmıştır. Sınıflandırmalar sonucu Veriseti-1, Veriseti-2 ve Veriseti-3 için elde edilen doğruluk, duyarlılık ve özgüllük değerleri sırasıyla Tablo 3.7, Tablo 3.8 ve Tablo 3.9’da sunulmuştur.

Tablo 3.7, Tablo 3.8 ve Tablo 3.9’da sunulan sonuçlar incelendiğinde öznitelik seçme aşamasında en yüksek doğruluk değerlerinin Veriseti-1, Veriseti-2 ve Veriseti-3 için sırasıyla %98,9, %94,4 ve %88,7 olduğu ve yine AlexNet + ResNet-101 sinir ağlarından elde edildiği görülmüştür. Bu değerler öznitelik çıkarma adımında elde edilen doğruluk değerleri ile karşılaştırıldığında ciddi bir artış olduğu görülmüştür. Bölüm 2 de sunulan Tablo 2.2’nin I ve IV numaralı sütunları incelendiğinde ise doğruluk değerlerindeki bu artışa rağmen Bölüm 2’de sunulan yöntemin öznitelik sayılarını önemli miktarda azalttığı görülmüştür.

Tablo 3.7. Veriseti-1 için binary genetik algoritma yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları

		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	97,0 ± 0,9	97,9 ± 1,1	97,9 ± 1,3
	SVM	98,5 ± 1,2	98,7 ± 1,3	97,8 ± 1,0
ResNet-101	KNN	97,1 ± 1,7	97,8 ± 1,5	97,5 ± 14
	SVM	97,8 ± 1,0	98,1 ± 0,9	97,0 ± 1,1
AlexNet + ResNet-101	KNN	96,4 ± 1,1	97,8 ± 1,3	97,1 ± 1,3
	SVM	98,9 ± 1,0	98,9 ± 1,1	98,0 ± 0,9

Tablo 3.8. Veriseti-2 için binary genetik algoritma yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları

		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	89,2 ± 2,1	84,8 ± 1,9	82,7 ± 2,3
	SVM	92,7 ± 1,3	90,2 ± 1,4	89,4 ± 1,0
ResNet-101	KNN	87,3 ± 2,1	81,9 ± 1,9	80,2 ± 2,2
	SVM	89,9 ± 1,7	83,5 ± 1,6	81,2 ± 1,6
AlexNet + ResNet-101	KNN	89,6 ± 1,8	86,8 ± 1,6	87,4 ± 1,9
	SVM	94,4 ± 1,2	92,8 ± 1,4	93,0 ± 1,7

Tablo 3.9. Veriseti-3 için binary genetik algoritma yöntemi kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları

		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	86,8 ± 1,7	87,3 ± 1,5	87,2 ± 1,5
	SVM	87,5 ± 1,6	88,4 ± 1,5	86,1 ± 1,2
ResNet-101	KNN	85,7 ± 1,3	86,0 ± 1,2	84,7 ± 1,5
	SVM	87,2 ± 0,9	86,3 ± 1,1	84,5 ± 1,0
AlexNet + ResNet-101	KNN	87,1 ± 1,2	87,9 ± 1,1	85,7 ± 1,0
	SVM	88,7 ± 1,1	88,3 ± 1,0	88,7 ± 1,2

Bölüm 2 de sunulan Tablo 2.2'nin I. ve IV. sütunlarındaki değerlerde görüldüğü gibi öznitelik çıkarma aşamasında veri setleri için AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağlarından elde edilen öznitelik sayıları sırasıyla 4096, 2048 ve 6144'tür. Ancak Bölüm 2'de sunulan yöntem sayesinde öznitelik sayısı, Veriseti-1, Veriseti-2 ve Veriseti-3 için sırasıyla ortalama %8,9, %8,7 ve %6,4'e düşürülmüştür. Öznitelik sayısındaki bu önemli azalmaya rağmen doğruluk değerlerinin önemli ölçüde arttığı Tablo 3.1-3.3 ile Tablo 3.7-3.9 karşılaştırıldığında rahatlıkla görülebilmektedir.

Örneğin Veriseti-1 için AlexNet sinir ağından öznitelik çıkarma aşamasında elde edilen öznitelik sayısı 4096'dır. Sunulan yöntemden sonra Veriseti-1 için AlexNet sinir ağından elde edilen öznitelik sayısı 366'ya düşmüştür. Bu düşüşe rağmen Tablo 3.1 ve 3.7'de görüldüğü gibi SVM sınıflandırıcısından elde edilen doğruluk değeri sunulan işlem hattı sonrasında %98,2'den %98,9'e çıkmıştır. Tablolardaki duyarlılık ve özgüllük değerleri incelendiğinde ise benzer durumun genel olarak duyarlılık ve özgüllük değerleri içinde geçerli olduğu görülmektedir.

Son olarak öznitelik çıkarma aşamasında elde edilen öznitelik vektörlerine öznitelik sıralama işlemi uygulanmadan sadece öznitelik seçme işlemi uygulansaydı elde edilen doğruluk değerlerinin nasıl değişeceği değerlendirilmiştir. Veriseti-1, Veriseti-2 ve Veriseti-3 için AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağlarından elde edilen öznitelik vektörlerine sadece BGA yönteminin uygulanması ile elde edilen doğruluk değerleri Tablo 3.10, Tablo 3.11 ve Tablo 3.12'de sunulmuştur.

Tablo 3.10, Tablo 3.11 ve Tablo 3.12'de sunulan sonuçlar incelendiğinde Veriseti-1, Veriseti-2 ve Veriseti-3 için öznitelik çıkarma aşamasında elde edilen öznitelik vektörlerine sadece öznitelik seçme işleminin uygulanmasıyla elde edilen en yüksek doğruluk değerlerinin sırasıyla %97,9, %88,9 ve %87,1 olduğu ve yine AlexNet + ResNet-101 sinir ağlarından elde edildiği görülmüştür. Bu değerler sunulan yöntemin tamamının kullanılmasıyla elde edilen doğruluk değerleriyle (Tablo 3.7, Tablo 3.8 ve Tablo 3.9) kıyaslandığında, sunulan yöntemin tamamının kullanılması ile elde edilen doğruluk değerlerinin daha yüksek olduğu görülmüştür. Bölüm 2 de sunulan Tablo 2.2'nin III ve IV numaralı sütunları incelendiğinde ise sunulan yöntemin tamamı kullanıldığında elde edilen öznitelik sayılarının sadece öznitelik çıkarma ve öznitelik seçme işlemlerinin uygulanması ile elde edilen öznitelik sayılarından daha az olduğu görülmüştür. Sunulan yöntemle elde edilen öznitelik sayısının daha az olmasına rağmen doğruluk değerlerinin yüksek olması öznitelik sıralama adımının öznitelikleri azaltmada önemli bir basamak olduğunu göstererek sunulan yöntemin etkinliğini bir kez daha kanıtlamıştır.

Tablo 3.10 Veriseti-1 için sadece öznitelik çıkarma ve öznitelik seçme işlemleri kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları

		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	96,5 ± 1,0	98,1 ± 2,1	95,2 ± 2,5
	SVM	98,2 ± 1,4	98,2 ± 1,9	96,0 ± 1,5
ResNet-101	KNN	95,1 ± 1,0	97,4 ± 1,2	94,4 ± 1,3
	SVM	96,1 ± 1,0	97,7 ± 1,7	95,1 ± 1,7
AlexNet + ResNet-101	KNN	96,0 ± 1,2	98,4 ± 1,1	94,4 ± 1,5
	SVM	97,9 ± 1,3	98,2 ± 1,5	97,1 ± 1,2

Tablo 3.11 Veriseti-2 için sadece öznitelik çıkarma ve öznitelik seçme işlemleri kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları

		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	87,1 ± 0,9	88,3 ± 1,2	86,2 ± 1,5
	SVM	88,7 ± 1,4	88,3 ± 1,5	86,9 ± 1,2
ResNet-101	KNN	86,3 ± 1,2	86,1 ± 2,1	85,1 ± 2,3
	SVM	87,8 ± 1,2	87,7 ± 1,4	86,5 ± 1,0
AlexNet + ResNet-101	KNN	87,1 ± 1,3	89,8 ± 1,1	85,2 ± 0,9
	SVM	88,9 ± 1,1	89,8 ± 0,9	87,4 ± 0,9

Tablo 3.12 Veriseti-3 için sadece öznitelik çıkarma ve öznitelik seçme işlemleri kullanılarak elde edilen boyutu azaltılmış öznitelik vektörlerinin sınıflandırma sonuçları

		Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	KNN	86,2 ± 1,3	84,2 ± 1,4	84,4 ± 1,3
	SVM	87,0 ± 1,6	86,2 ± 1,3	86,0 ± 1,2
ResNet-101	KNN	85,7 ± 2,2	84,1 ± 2,3	82,8 ± 1,9
	SVM	86,1 ± 1,8	86,3 ± 1,1	84,7 ± 1,4
AlexNet + ResNet-101	KNN	85,2 ± 1,4	84,7 ± 1,7	82,3 ± 0,9
	SVM	87,1 ± 1,3	86,3 ± 0,9	84,6 ± 1,1

Bunlara ek olarak her aşamada elde edilen doğruluk değerleri incelendiğinde en yüksek doğruluk değerlerinin SVM sınıflandırma yöntemi ile gerçekleştirilen deneylerden elde edildiği gözlemlenmiştir. KNN sınıflandırma yönteminden elde edilen sonuçlar incelendiğinde ise tüm sinir ağları için oldukça iyi sonuçlar elde edilmiş olsa da KNN yönteminin SVM yönteminden biraz geride kaldığı görülmüştür.

Elde edilen sonuçların anlamlı olup olmadığını değerlendirmek için Bölüm 3.3'te istatistiksel anlamlılık testleri ve sonuçları detaylı olarak açıklanmıştır.

3.3. İstatistiksel Anlamlılık Sonuçları

İstatistiksel anlamlılık testleri AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağlarından alınan öznitelik vektörlerine sunulan yöntemin uygulanması sonucu elde edilen vektörler üzerinde gerçekleştirilmiştir. Yaklaşımlardan hangisinin daha iyi bir performans sunduğu KNN ve SVM sınıflandırma yöntemleri ile 30 kez gerçekleştirilen deneylerden elde edilen doğruluk değerlerinden faydalanılarak değerlendirilmiştir. Bütün değerlendirmeler Veriseti-1, Veriseti-2 ve Veriseti-3 için ayrı ayrı gerçekleştirilmiştir.

KNN sınıflandırma yöntemi ile gerçekleştirilen deneylere yönelik Shapiro-Wilk testi sonuçları Tablo 3.13'te sunulmuştur. Tablo 3.13'te görüldüğü gibi Veriseti-1 için AlexNet ile gerçekleştirilen deneylerden elde edilen anlamlılık değeri 0,05'ten azdır.

Benzer şekilde Veriseti-2 için AlexNet, ResNet-101'den ve Veriseti-3 için AlexNet + ResNet-101'den elde edilen doğruluk değeri sonuçlarının anlamlılık değerleri 0,05'in altındadır. Veri setlerine ait anlamlılık değerlerinden en az birinin anlamlılık değeri 0,05'den küçük olduğundan doğruluk değerleri normal bir dağılım izlememektedir.

Normalizasyon testinden sonra KNN sınıflandırma yöntemi ile gerçekleştirilen deneylerde sinir ağları arasında anlamlı bir fark olup olmadığı Kruskal-Wallis testinden faydalanılarak değerlendirilmiştir. Elde edilen sonuçlar Tablo 3.14'te sunulmuştur. Tablo 3.14'teki anlamlılık değerleri (p-value) incelendiğinde bütün değerlerin 0,05'ten küçük olduğu görülmektedir. Bu durum tüm veri setleri için kullanılan sinir ağları arasında anlamlı bir fark olduğunu göstermektedir.

Daha sonra KNN sınıflandırma yöntemi ile gerçekleştirilen deneylerde sinir ağlarından hangisinin/hangilerinin istatistiksel olarak farklı olduğunu belirlemek amacı ile Mann-Whitney U testinden faydalanılmıştır. Elde edilen sonuçlar Tablo 3.15'te sunulmuştur. Tablo 3.15'teki anlamlılık değerleri (p-value) incelendiğinde bütün değerlerin 0,05'ten küçük olduğu görülmektedir. Bu durumda Mann-Whitney U testinin Sıfır Hipotezi reddedilir ve tüm veri setleri için kullanılan sinir ağları arasında anlamlı bir fark olduğu sonucuna varılır.

Tablo 3.13. KNN algoritması ile gerçekleştirilen deneylerle ilgili veri setleri için sinir ağlarına ait normallik testi sonuçları

Veri Setleri	Yöntem	Anlamlılık Değeri (p)
VeriSeti-1	AlexNet	0,03
	ResNet-101	0,84
	AlexNet + ResNet-101	0,78
VeriSeti-2	AlexNet	0,02
	ResNet-101	0,01
	AlexNet + ResNet-101	0,42
VeriSeti-3	AlexNet	0,31
	ResNet-101	0,27
	AlexNet + ResNet-101	0,01

Tablo 3.14. KNN algoritması ile gerçekleştirilen deneylerde sinir ağları için elde edilen Kruskal-Wallis test sonuçları.

Veri Setleri	Kruskal-Wallis H Değeri	Anlamlılık Değeri (p)
VeriSeti-1	15,24	<0,001
VeriSeti-2	81,18	<0,001
VeriSeti-3	9,86	0,01

Tablo 3.15. KNN algoritması ile gerçekleştirilen deneylerde sinir ağırları için elde edilen Mann-Whitney U test sonuçları

Veri Setleri	Gruplar	Anlamlılık Değeri (p)
VeriSeti-1	AlexNet ve ResNet-101	<0,001
	AlexNet ve AlexNet + Resnet-101	<0,001
	ResNet ve AlexNet + ResNet-101	<0,001
VeriSeti-2	AlexNet ve ResNet-101	<0,001
	AlexNet ve AlexNet + Resnet-101	<0,001
	ResNet ve AlexNet + ResNet-101	<0,001
VeriSeti-3	AlexNet ve ResNet-101	<0,001
	AlexNet ve AlexNet + Resnet-101	<0,001
	ResNet ve AlexNet + ResNet-101	0,01

SVM sınıflandırma yöntemi ile gerçekleştirilen deneylere yönelik Shapiro-Wilk testi sonuçları Tablo 3.16’da sunulmuştur. Tablo 3.16’da görüldüğü gibi Veriseti-1 için AlexNet ve ResNet-101 ile gerçekleştirilen deneylerden elde edilen anlamlılık değerleri 0,05’ten azdır. Benzer şekilde Veriseti-2 için AlexNet ve ResNet-101, Veriseti-3 için ResNet-101’den elde edilen doğruluk sonuçlarının anlamlılık değerleri 0,05’in altındadır. Veri setlerine ait anlamlılık değerlerinden en az birinin anlamlılık değeri 0,05’ den küçük olduğundan doğruluk değerleri normal bir dağılım izlememektedir.

Normalizasyon testinden sonra SVM sınıflandırma yöntemi ile gerçekleştirilen deneylerde sinir ağırları arasında anlamlı bir fark olup olmadığı Kruskal-Wallis testinden faydalanılarak değerlendirilmiştir. Elde edilen sonuçlar Tablo 3.17’de sunulmuştur. Tablo 3.17’deki anlamlılık değerleri (p-value) incelendiğinde bütün değerlerin 0,05’ten küçük olduğu görülmektedir. Bu durum tüm veri setleri için kullanılan sinir ağırları arasında anlamlı bir fark olduğunu göstermektedir.

Daha sonra SVM sınıflandırma yöntemi ile gerçekleştirilen deneylerde sinir ağlarından hangisinin/hangilerinin istatistiksel olarak farklı olduğunu belirlemek amacı ile Mann-Whitney U testinden faydalanılmıştır. Elde edilen sonuçlar Tablo 3.18’de sunulmuştur. Tablo 3.18’deki anlamlılık değerleri (p-value) incelendiğinde bütün değerlerin 0,05’ten küçük olduğu görülmektedir. Bu durumda Mann-Whitney U testinin Sıfır Hipotezi reddedilir ve tüm veri setleri için kullanılan sinir ağları arasında anlamlı bir fark olduğu sonucuna varılır.

Tablo 3.16. SVM algoritması ile gerçekleştirilen deneylerde ilgili veri setleri için sinir ağlarına ait normallik testi sonuçları

Veri Setleri	Yöntem	Anlamlılık Değeri (p)
VeriSeti-1	AlexNet	0,04
	ResNet-101	0,01
	AlexNet + ResNet-101	0,49
VeriSeti-2	AlexNet	0,03
	ResNet-101	0,04
	AlexNet + ResNet-101	0,59
VeriSeti-3	AlexNet	0,80
	ResNet-101	0,02
	AlexNet + ResNet-101	0,29

Tablo 3.17. SVM algoritması ile gerçekleştirilen deneylerde sinir ağırları için elde edilen Kruskal-Wallis test sonuçları

Veri Setleri	Kruskal-Wallis H Değeri	Anlamlılık Değeri (p)
VeriSeti-1	79,17	<0,001
VeriSeti-2	33,74	<0,001
VeriSeti-3	53,87	<0,001

Tablo 3.18. SVM algoritması ile gerçekleştirilen deneylerde sinir ağırları için elde edilen Mann-Whitney U test sonuçları

Veri Setleri	Gruplar	Anlamlılık Değeri (p)
VeriSeti-1	AlexNet ve ResNet-101	<0,001
	AlexNet ve AlexNet + Resnet-101	<0,001
	ResNet ve AlexNet + ResNet-101	<0,001
VeriSeti-2	AlexNet ve ResNet-101	0,01
	AlexNet ve AlexNet + Resnet-101	<0,001
	ResNet ve AlexNet + ResNet-101	<0,001
VeriSeti-3	AlexNet ve ResNet-101	<0,001
	AlexNet ve AlexNet + Resnet-101	<0,001
	ResNet ve AlexNet + ResNet-101	0,01

Bu istatistiksel analizler AlexNet, ResNet-101 ve AlexNet + ResNet-101 sinir ağılarından elde edilen özniteliklere sunulan yöntemin uygulanması ile alınan sınıflandırma sonuçları arasında istatistiksel olarak anlamlı farklılıkların olduğunu göstermiştir.



4. BÖLÜM

SONUÇ TARTIŞMA VE ÖNERİLER

4.1. Sonuç

Bu tez çalışmasında öznitelik çıkarma, öznitelik sıralama, öznitelik seçme ve sınıflandırma aşamalarından oluşan bir yöntem sunulmuştur. Yöntemin anlamlılığı istatistiksel analizlerle değerlendirilmiştir.

Öznitelik çıkarma adımı bu çalışmada kullanılan veri setlerindeki tüm tıbbi görüntüler için AlexNet, ResNet-101 ve AlexNet + ResNet-101 CNN modelleri kullanılarak ayrı ayrı sayısal değerlerden oluşan öznitelik vektörleri oluşturulmuştur. Toplamda sadece bir veri seti için öznitelik vektörlerinden oluşan 3 farklı veri seti elde edilmiştir.

Öznitelik sıralama adımı iki örneklemlili z-test yöntemi ile oluşturulan öznitelik vektörlerinin sınıfları arasındaki farklılığı belirgin derecede ortaya koyan öznitelikler seçilerek vektörlerin boyutu azaltılmıştır.

Öznitelik seçme adımı boyutu azaltılmış öznitelik vektörlerindeki özniteliklerden sınıflandırmada etkili olanlar, BGA yöntemi kullanılarak seçilmiştir. Böylelikle başlangıçta CNN modelleri kullanılarak üretilen öznitelik vektörlerinin boyutu büyük oranında küçültülmüştür.

Sınıflandırma adımı seçilen bu en iyi öznitelikler 4-katlı çapraz doğrulama ile KNN ve SVM sınıflandırma yöntemleri kullanılarak sınıflandırılmıştır. Her bir sınıflandırma işlemi istatistiksel analizleri gerçekleştirmek için 30 kez tekrarlanmıştır. Elde edilen değerlerin ortalamaları Bölüm 3'te sunulmuştur.

Bu çalışmadan elde edilen tüm sonuçlar değerlendirildiğinde AlexNet + ResNet-101 sinir ağlarından elde edilen öznitelik vektörlerine sunulan yöntemin uygulanması ve SVM sınıflandırıcısı kullanarak sınıflandırması yaklaşımının farklı görüntüleme modaliteleri kullanılarak elde edilmiş tıbbi görüntülerin yüksek doğrulukla sınıflandırılmasında başarılı olduğunu göstermiştir.

Sunulan yöntem sayesinde tıbbi görüntülerin çok az öznitelikle, hızlı ve yüksek doğrulukla sınıflandırılmasını sağlayan ve bu yolla düşük maliyetli donanımlar üzerinde gerçekleştirilecek bir karar destek sistemi önerilmiştir. Sunulan karar destek sistemi hastanelere kolaylıkla entegre edilebilecek, tıp profesyonellerinin iş yükünü ve muayene sürelerini azaltacak, özellikle daha alt seviyedeki sağlık personelinin hastalık teşhisi koymalarına destek olacak bir sistemdir. Bu sistem sayesinde özellikle gelişmemiş ya da gelişmekte olan ülkelerde teşhis ve tedavideki gecikmelerden kaynaklanan mortalite ve morbidite oranlarındaki artışın önüne geçilebilecektir.

4.2.Tartışma

Literatürde mevcut çalışmalar incelendiğinde CNN ve yapay zekâ modellerinin görüntü verilerini etkin bir şekilde sınıflandırabildiği görülmüştür. Ancak CNN ve benzeri yapay zekâ modellerinin yapılarındaki parametre sayısının fazlalığı sebebiyle bu türden modellerin gerçekleştirilmesi için ihtiyaç duyulan fiziksel donanımların işlem kapasitelerinin oldukça yüksek olması gerekmektedir. Bu türden sistemlerin maliyetlerinin oldukça yüksek olması yapay zekâ tabanlı sistemlerin yaygınlaşmasını önemli ölçüde engellemektedir. CNN ve yapay zekâ modellerinin işlemsel yükünü hafifletmek için kullanılan yöntemlerin ise işlem yükünü bir nebze hafifleterek sınıflandırma performansını olumlu etkilese de yeterli olmadığı görülmüştür. Ayrıca işlemsel yükü hafifletmek için geliştirilen yöntemlerin sadece tek bir görüntüleme modalitesi ile elde edilmiş tıbbi görüntüler üzerinde test edildiği, farklı görüntüleme yöntemleri kullanılarak elde edilmiş tıbbi görüntüler üzerinde değerlendirilmediği gözlemlenmiştir. CNN ve benzeri yapay zekâ modellerinin yapılarındaki parametre sayısının fazlalığı göz önüne alındığında literatürdeki bu çalışmaların düşük maliyetli donanımlar üzerinde gerçekleştirilmesi oldukça zor ve maliyetlidir.

Bu yüzden literatürdeki çalışmaların eksikliklerini giderebilecek, düşük maliyetli donanımlar üzerinde gerçekleştirilebilecek, farklı tipteki tıbbi görüntüleri kullanarak hastalıkları yüksek doğrulukla teşhis edebilecek bir sistem geliştirilmesi oldukça önemlidir. Bu çalışmada sunulan yöntemin bu eksikliği giderebileceği deneysel sonuçlar bölümünde kanıtlanmıştır. Sunulan yöntem sayesinde oldukça yüksek boyuta sahip tıbbi görüntü verileri çok az sayıda öznitelikle başarılı şekilde temsil edilebilmiştir. Sunulan yöntem bu yolla görüntü verilerinin CNN ve benzeri karmaşık derin öğrenme modelleri ile sınıflandırılması yerine, bu görüntü verilerini temsil eden çok daha düşük boyutlu öznitelik vektörlerinin daha basit ve işlemsel karmaşıklığı çok daha düşük makine öğrenmesi modelleriyle sınıflandırılmasına imkân sağlamıştır.

4.3. Öneriler

Bu tez çalışmasında ikili sınıflandırma üzerine yoğunlaşıldığı için sunulan yaklaşımın etkinliği ikiden fazla sınıfa sahip veri setleri üzerinde değerlendirilmemiştir. Bu yüzden gelecekte gerçekleştirilebilecek bir çalışma olarak sunulan yaklaşımın etkinliği ikiden fazla sınıfa sahip veri setleri üzerinde değerlendirilebilir. Ayrıca bu çalışmada kullanılan iki örneklemlili z-testi ve BGA yöntemi oldukça iyi sonuçlar vermiş olsa da bu yöntemlerden daha iyi sonuç verebilecek yöntemlerin olup olmadığı araştırılabilir.

KAYNAKÇA

- [1] Hill, D.L.G., Batchelor, P.G., Holden, M., Hawkes, D. J. 2001. Physics in medicine & biology medical image registration medical image registration, **Medicine And Biology**, **46**, 1-45, Eriřim: 04 Temmuz 2024.
- [2] Ritter, F., Boskamp, T., Homeyer, A., Laue, H., Schwier, M., Link, F., & Peitgen, H. O. 2011. Medical image analysis. **IEEE Pulse**, **2**(6), 60–70.
- [3] Meskó, B., Hetényi, G., & Gyorffy, Z. 2018. Will artificial intelligence solve the human resource crisis in healthcare?. **BMC Health Services Research**, **18**(1), 1–4.
- [4] WHO health workforce support and safeguards list 2023. (Web Sayfası: <https://www.who.int/publications/i/item/9789240069787>), (Eriřim tarihi: 04 Temmuz 2024).
- [5] Toğaçar, M., Cömert, Z., & Ergen, B. 2021. Intelligent skin cancer detection applying autoencoder, MobileNetV2 and spiking neural networks. **Chaos, Solitons & Fractals**, **144**, 110714.
- [6] Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C. S., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F., Dong, J., Prasadha, M. K., Pei, J., Ting, M., Zhu, J., Li, C., Hewett, S., Dong, J., Ziyar, I., ... Zhang, K. 2018. Identifying medical diagnoses and treatable diseases by image-based deep learning. **Cell**, **172**(5), 1122-1131.
- [7] Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., & Chen, M. 2014. Medical image classification with convolutional neural network, 844–848. *2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014*.
- [8] Yadav, S. S., & Jadhav, S. M. 2019. Deep convolutional neural network based medical image classification for disease diagnosis. **Journal of Big Data**, **6**(1), 1–18.
- [9] Dutta, P., Upadhyay, P., De, M., & Khalkar, R. G. 2020. Medical Image Analysis using Deep Convolutional Neural Networks: CNN Architectures and Transfer Learning, 175–180. *Proceedings of the 5th International Conference on Inventive Computation Technologies, ICICT 2020*.

- [10] Huang, M. L., & Liao, Y. C. 2022. A lightweight CNN-based network on COVID-19 detection using X-ray and CT images. **Computers in Biology and Medicine**, **146**, 105604.
- [11] Nasiri, H., & Alavi, S. A. 2022. A novel framework based on deep learning and anova feature selection method for diagnosis of COVID-19 cases from chest X-ray images. **Computational Intelligence and Neuroscience**.
- [12] El-Kenawy, E. S. M., Ibrahim, A., Mirjalili, S., Eid, M. M., & Hussein, S. E. 2020. Novel feature selection and voting classifier algorithms for COVID-19 classification in CT images. **IEEE Access**, **8**.
- [13] Iraj, M. S., Feizi-Derakhshi, M. R., & Tanha, J. 2021. COVID-19 detection using deep convolutional neural networks and binary differential algorithm-based feature selection from x-ray images. **Complexity**, **2021**(1), 9973277.
- [14] Pramanik, R., Sarkar, S., & Sarkar, R. 2022. An adaptive and altruistic pso-based deep feature selection method for pneumonia detection from chest x-rays. **Applied Soft Computing**, **128**, 109464.
- [15] Aslan, N., Ozmen Koca, G., Kobat, M. A., & Dogan, S. 2022. Multi-classification deep CNN model for diagnosing COVID-19 using iterative neighborhood component analysis and iterative ReliefF feature selection techniques with X-ray images. **Chemometrics and Intelligent Laboratory Systems**, **224**, 104539.
- [16] Benyahia, S., Meftah, B., & L  zoray, O. 2022. Multi-features extraction based on deep learning for skin lesion classification. **Tissue and Cell**, **74**, 101701.
- [17] Akram, T., Lodhi, H. M. J., Naqvi, S. R., Naeem, S., Alhaisoni, M., Ali, M., Haider, S. A., & Qadri, N. N. 2020. A multilevel features selection framework for skin lesion classification. **Human-Centric Computing and Information Sciences**, **10**(1), 1–26.
- [18] Khanna, P., Sahu, M., & Kumar Singh, B. 2021. Improving the classification performance of breast ultrasound image using deep learning and optimization algorithm. *2021 IEEE International Conference on Technology, Research, and Innovation for Betterment of Society, TRIBES 2021*.

- [19] Alhussan, A. A., Eid, M. M., Towfek, S. K., & Khafaga, D. S. 2023. Breast cancer classification depends on the dynamic dipper throated optimization algorithm. **Biomimetics** 8(2), 163.
- [20] Agrawal, V., ve Chandra, S. 2015. Feature selection using Artificial Bee Colony algorithm for medical image classification, 171–176. *2015 8th International Conference on Contemporary Computing, IC3 2015*.
- [21] Sathya Priya, T., ve Ramaprabha, T.A. 2021. Resnet based feature extraction with decision tree classifier for classificaton of mammogram images. **Turkish Journal of Computer and Mathematics Education (TURCOMAT)**, 12(2), 1147–1153.
- [22] Elswah, D. K., Elnakib, A. A., ve El-Din Moustafa, H. 2020. Automated diabetic retinopathy grading using resnet, 248–254. *National Radio Science Conference, NRSC, Proceedings, 2020-September*.
- [23] Beheshti, I., Demirel, H., & Matsuda, H. 2017. Classification of Alzheimer’s disease and prediction of mild cognitive impairment-to-Alzheimer’s conversion from structural magnetic resource imaging using feature ranking and a genetic algorithm. **Computers in Biology and Medicine**, 83, 109–119.
- [24] Bozkurt, T. N., Yüksel, M. E. 2023. A Novel decision support system based on feature extraction, feature ranking, feature selection for accurate diagnosis of diseases using medical images, 64–67. *33rd International Symposium on Pharmaceutical and Biomedical Analysis, Ankara*.
- [25] “ISIC | International Skin Imaging Collaboration”. (Web sayfası: <https://www.isic-archive.com/>), (Erişim tarihi: 04 Temmuz 2024).
- [26] Al-Dhabyani, W., Gomaa, M., Khaled, H., & Fahmy, A. 2020. Dataset of breast ultrasound images. **Data in Brief**, 28, 104863.
- [27] Guyon, I., & Elisseeff, A. 2006. An introduction to feature extraction. **Studies in Fuzziness and Soft Computing**, 207, 1–25.
- [28] Jogin, M., Mohana, Madhulika, M. S., Divya, G. D., Meghana, R. K., & Apoorva, S. 2018. Feature extraction using convolution neural networks (CNN) and deep learning,

2319–2323. *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology, RTEICT 2018 – Proceedings.*

- [29] Elngar, A. A., Arafa, M., Fathy, A., Moustafa, B., Mahmoud, O., Shaban, M., & Fawzy, N. 2021. Image classification based on CNN: A survey. **Journal of Cybersecurity and Information Management (JCIM)**, 6(1), 18.
- [30] Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Van Esesn, B. C., Awwal, A. A. S., & Asari, V. K. 2018. The history began from alexnet: a comprehensive survey on deep learning approaches.
- [31] Ghosal, P., Nandanwar, L., Kanchan, S., Bhadra, A., Chakraborty, J., & Nandi, D. 2019. Brain tumor classification using ResNet-101 based squeeze and excitation deep neural network. *2019 2nd International Conference on Advanced Computational and Communication Paradigms, ICACCP 2019.*
- [32] Chang, Y.-W., Lin, C.-J., Guyon, I., Aliferis, C., Cooper, G., Elisseeff, A., Pellet, J.-P., Spirtes, P., & Statnikov, A. (n.d.). Feature Ranking Using Linear SVM, 53–64. *JMLR: Workshop and Conference Proceedings.*
- [33] Duch, W., Wiecezorek, T., Biesiada, J., & Blachnik, M. 2004. Comparison of feature ranking methods based on information entropy, 2, 1415–1419. *IEEE International Conference on Neural Networks - Conference Proceedings.*
- [34] Yu, H., Oh, J., & Han, W. S. 2009. Efficient feature weighting methods for ranking, 1157–1165. *International Conference on Information and Knowledge Management, Proceedings.*
- [35] Wang, H., Khoshgoftaar, T. M., & Gao, K. 2010. A comparative study of filter-based feature ranking techniques, 43–48. *2010 IEEE International Conference on Information Reuse and Integration, IRI 2010.*
- [36] Zaykin, D. V. 2011. Optimally weighted Z-test is a powerful method for combining probabilities in meta-analysis. **Journal of Evolutionary Biology**, 24(8), 1836–1841.
- [37] Kumar, V., & Minz, S. 2014. Smart computing review feature selection: a literature review. **Smart Computing Review**, 4(3).

- [38] Guyon, I., & De, A. M. 2003. An introduction to variable and feature selection andré elisseeff. **Journal of Machine Learning Research**, **3**, 1157–1182.
- [39] Mathew, T. V., Genetic Algorithm.
- [40] Aalaei, S., Shahraki, H., Rowhanimanesh, A., & Eslami, S. 2016. Feature selection using genetic algorithm for breast cancer diagnosis: experiment on three different datasets. **Iranian Journal of Basic Medical Sciences**, **19**(5), 476.
- [41] Babatunde, O., Armstrong, L., Leng, J., & Diepeveen, D. 2014. A genetic algorithm-based feature selection. **Research Outputs 2014 to 2021**.
- [42] Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. 2006. Machine learning: A review of classification and combining techniques. **Artificial Intelligence Review**, **26**(3), 159–190.
- [43] Saravanan, R., & Sujatha, P. 2018. A state of art techniques on machine learning algorithms: A perspective of supervised learning approaches in data classification, 945–949. *Proceedings of the 2nd International Conference on Intelligent Computing and Control Systems, ICI CCS 2018*.
- [44] Zhang, Z. 2016. Introduction to machine learning: k-nearest neighbors. **Annals of Translational Medicine**, **4**(11).
- [45] Moldagulova, A., & Sulaiman, R. B. 2017. Using KNN algorithm for classification of textual documents. 665–671. *ICIT 2017 - 8th International Conference on Information Technology, Proceedings*.
- [46] Xiao, R., Wang, J., & Zhang, F. 2000. An approach to incremental SVM learning algorithm. 268–273. *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI, 2000-January*.
- [47] Mammone, A., Turchi, M., & Cristianini, N. 2009. Support vector machines. **Wiley Interdisciplinary Reviews: Computational Statistics**, **1**(3), 283–289.
- [48] Erickson, B. J., & Kitamura, F. 2021. Magician’s corner: 9. performance metrics for machine learning models. **Radiology: Artificial Intelligence**, **3**(3).

- [49] Islaqm, M. R., & Islam, M. R. 2018. Sample size and its role in Central Limit Theorem (CLT). **Computational and Applied Mathematics Journal**, 4(1), 1–7.
- [50] Kwak, S. G., & Kim, J. H. 2017. Central limit theorem: the cornerstone of modern statistics. **Korean Journal of Anesthesiology**, 70(2), 144–156.
- [51] Mohd Razali, N., & Bee Wah, Y. 2011. Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. **Journal of Statistical Modeling and Analytics**, 2, 21–33.
- [52] Ozcan, T., & Basturk, A. 2019. Transfer learning-based convolutional neural networks with heuristic optimization for hand gesture recognition. **Neural Computing and Applications**, 31(12), 8955–8970.
- [53] Mann, H. B., & Whitney, D. R. 1947. On a Test of Whether one of Two Random Variables is Stochastically Larger than the Other. 18(1), 50–60.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Tuğba Nur BOZKURT

Uyruğu: Türkiye (T.C)

Doğum Tarihi ve Yeri:

Medeni Durum:

e-mail:

Yazışma Adresi:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	T.C. Erciyes Üniversitesi, Biyomedikal Mühendisliği Bölümü	2024
Lisans	T.C. Erciyes Üniversitesi, Biyomedikal Mühendisliği Bölümü	2021
Lise	Özel Fen Bilimleri Temel Lisesi, Kayseri	2017

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2023-Halen	T.C. Yeditepe Üniversitesi	Arş. Gör.

YABANCI DİL

İngilizce

YAYINLAR

- Yüksel, ME., Bozkurt TN., 2023. A Novel Decision Support System Based on Feature Extraction, Feature Ranking, Feature Selection for Accurate Diagnosis of Diseases Using Medical Images, 64-67. *33rd International Symposium on Pharmaceutical and Biomedical Analysis (PBA 2023)*, 2023, Ankara, Ankara Üniversitesi, 282

PROJE

1. Yüksel, ME., Bozkurt, TN., Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi Destekli Proje, Tıbbi Görüntülerin Derin Öğrenme Yöntemleriyle Analiz Edilmesi, 2023-2024

FAYDALI MODEL

1. Akdoğan, G., Bozkurt, T.N., Öztürk, B., 2023. Türk Patent ve Marka Kurumu, Yara Önleyici Medikal Ayakkabı. TR 2022 007600 Y, Kasım 11, 2023.

