



T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**MEME KANSERİNİN İYİ HUYLU VEYA
KÖTÜ HUYLU DURUM TESPİTİNDE DERİN
ÖĞRENME MODELLERİNİN
KULLANILMASI**

Feyzi Ferat ATEŞ

YÜKSEK LİSANS

Danışman: Dr. Öğr. Üyesi Abidin ÇALIŞKAN

Elektrik Elektronik Mühendisliği Anabilim Dalı

Şubat-2023
BATMAN
Her Hakkı Saklıdır.

TEZ KABUL VE ONAYI

Feyzi Ferat ATEŞ tarafından hazırlanan “**MEME KANSERİNİN İYİ HUYLU VEYA KÖTÜ HUYLU DURUM TESPİTİNDE DERİN ÖĞRENME MODELLERİNİN KULLANILMASI**” adlı tez çalışması 21/02/2023 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS** olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç. Dr. Yılmaz KAYA

Danışman

Dr. Öğr. Üyesi Abidin ÇALIŞKAN

Üye

Doç. Dr. Melih KUNCAN

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Osman PAKMA
Lisansüstü Eğitim Enstitüsü Müdür V.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Feyzi Ferat ATEŞ

21/02/2023

ÖZET

YÜKSEK LİSANS

MEME KANSERİNİN İYİ HUYLU VEYA KÖTÜ HUYLU DURUM TESPİTİNDE DERİN ÖĞRENME MODELLERİNİN KULLANILMASI

Feyzi Ferat ATEŞ

**Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Abidin ÇALIŞKAN

2023, 85 Sayfa

Jüri

Danışman: Dr. Öğr. Üyesi Abidin ÇALIŞKAN

Doç. Dr. Yılmaz KAYA

Doç. Dr. Melih KUNCAN

Meme kanseri, meme de bulunan bağ dokusu ve buna bağlı olan kanal bölgelerinde oluşan ve oluşan bu hücrelerin normalin dışında hareketlerinden meydana gelen bir kanser türüdür. Yoğun olarak kadınlarda görülmekte olup, en yaygın rastlanan kanser çeşitlerindendir. Hastalık erkenden fark edilmeği zaman kan ve lenf damarları yoluyla diğer organlara kanserli hücreler etki edebilir (metastaz durumu). Yapılan araştırmalara göre genel olarak tüm kanser çeşitlerinde erken tanı ve tedavi önemlidir. Bu çalışmada meme kanserinin iyi huylu ve kötü huylu türleri arasında sınıflandırma yapabilen yapay zekâ tabanlı erken tanı sistemi önerilmiştir. Önerilen yaklaşımda artık bloklu evrimsel sinir ağı modelleri kullanıldı. ResNet modellerinin son katmanına yeni bir tam bağlantılı katman eklenerek tür tabanlı öznetelikler çıkartıldı. Bir sonraki aşamada tam bağlantılı katmanlardan elde edilmiş öznetelikler birleştirilerek yeni bir özellik seti oluşturuldu. Oluşturulan bu özellik seti ile sınıflandırma oluşturulurken softmax ve makine öğrenim yöntemleri kullanıldı. Çalışmada önerilen yaklaşım ile sınıflandırma oluşturulma adımlarında kullanılan tüm yöntemlerden %100 genel doğruluk başarıları elde edildi. Bu çalışmada tam bağlantılı katmanların elde edilmesi ve birleştirilmesi deneysel analizlerin geliştirilen çalışmada performansla olumlu yönde etki ettiği gözlemlenmiştir.

Anahtar Kelimeler: Derin öğrenme, sınıflandırma, özellik seçimi, makine öğrenmesi, meme kanseri, yapay zekâ

ABSTRACT

MS THESIS

USING DEEP LEARNING MODELS FOR BREAST CANCER DETECTION OF BECOME OR VIOLENT CONDITIONS

Feyzi Ferat ATEŞ

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
BATMAN UNIVERSITY**

**THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL ELECTRONICS ENGINEERING**

Advisor: Asst. Prof. Dr. Abidin ÇALIŞKAN

2023, 85 Pages

Jury

Asst. Prof. Dr. Abidin ÇALIŞKAN

Assoc. Prof. Dr. Yılmaz KAYA

Assoc. Prof. Dr. Melih KUNCAN

Breast cancer is a type of cancer that usually occurs in the lobule, duct and connective tissue regions of the breast and is caused by the abnormal movement of cells in these regions. The most common type of cancer in women is breast cancer. When the disease is detected early, cancerous cells can affect other organs through the blood and lymphatic vessels (metastasis state). Therefore, early diagnosis and treatment of breast cancer is important. This study proposes the classification of benign and malignant types of breast cancer with an artificial intelligence-based early diagnosis system. Blocky neural network models are now used in the proposed approach. Type-based features were extracted by adding a new fully connected layer to the last layer of ResNet models. In the next step, a new feature set was created by combining the features obtained from the fully connected layers. Softmax and machine learning methods were used while creating the classification with this feature set. With the approach proposed in the study, 100% overall accuracy was obtained from all the methods used in the classification creation steps. In this study, it was observed that obtaining and combining type-based fully connected layers positively affected the performance of experimental analyzes.

Keywords: Deep learning, classification, feature selection, machine learning, breast cancer, artificial intelligence

ÖNSÖZ

Yüksek lisans eğitimim boyunca ve çalışmalarımda beni destekleyen, yönlendiren, fikirleri ile sürekli gelişimimi sağlayan danışmanım Sayın Dr. Öğr. Üyesi Abidin ÇALIŞKAN'a, deneyimlerini paylaşan Sayın Doç. Dr. Mesut TOĞAÇAR'a ve çalışmam boyunca beni sürekli destekleyen, maddi ve manevi her türlü konularda bana yardımcı olan aileme teşekkürlerimi bir borç bilirim.

Feyzi Ferat ATEŞ
BATMAN - 2023



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER.....	ix
ÇİZELGELER	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ.....	1
1.1. Radyolojik Tanı Yöntemleri	5
1.1.1. Mamogram	7
1.1.2. Ultrason Görüntüleme	9
1.1.3. Manyetik Rezonans Görüntüleme	11
1.1.4. Bilgisayarlı Tomografi	13
2. YAPAY ZEKÂ MODELLERİ	15
2.1. Yapay Zekâ	19
2.1.1. Matematikte Yapay Zekâ	24
2.1.2. Tıp Biliminde Yapay Zekâ	25
2.1.3. Yaşam Bilimlerinde Yapay Zekâ	27
2.2. Makine Öğrenme Yöntemleri	28
2.2.1. Destek Vektör Makineleri	29
2.2.2. K-En Yakın Komşuluk	33
2.2.3. Lineer Diskriminant Analizi	36
2.3. Derin Öğrenme	40
2.4. Evrişimli Sinir Ağları.....	41
2.4.1. Giriş Katmanı	42
2.4.2. Evrişim Katmanı	42
2.4.3. Havuzlama Katmanı	43
2.4.4. Tam Bağlantılı Katman.....	45
2.4.5. Çıkış Katmanı	45
2.5. Transfer Öğrenme Modelleri	45
2.5.1. ResNet	46
2.5.2. AlexNet.....	47
2.5.3. GoogleNet.....	48
3. KAYNAK ARAŞTIRMASI	49
4. MATERYAL VE YÖNTEM.....	52

4.1. Veri Kümesi	52
4.2. Önerilen Hibrit Yaklaşım.....	53
4.3. Artık Tabanlı Derin Öğrenme Modelleri	56
5. DENEY ANALİZLER VE TARTIŞMA.....	60
6. SONUÇLAR VE ÖNERİLER.....	67
7. KAYNAKLAR	68
8. ÖZGEÇMİŞ	85



ŞEKİLLER

Şekil 1.1. Mamogram görüntüsü.....	9
Şekil 1.2. Soldaki normal meme parankimde sıvı dolu test görüntüsü, sağdaki ultrason ile tespit edilmiş ok ile gösterilen başlangıç yeri yeni olan meme kanseri görüntüsüdür.....	11
Şekil 1.3. (a) Normal bir meme MR görüntüsü (b) Bir Tümörün MR görüntüsü.....	13
Şekil 1.4. Deride yaygın kalınlaşma, meme yoğunluğunda asimetri ve yaygın sol aksiller lenfadenopatiyi gösteren BT taramasının seçilmiş görüntüsü	14
Şekil 2.1. Yapay zekâ ve bilgi işleyişi.....	24
Şekil 2.2. DVM sınıflandırma süreci; a) ikili sınıflandırma, b) çoklu sınıflandırma.....	33
Şekil 2.3. Orijinal veri setleri ve test vektörleri.....	37
Şekil 2.4. Evrişim katmanında özellik çıkarma işlemi.....	43
Şekil 2.5. 3x3'lük bir filtre kullanılarak maksimum (a), minimum (b) ve ortalama (c) havuzlama yöntemlerinin uygulanması.....	44
Şekil 2.6. ResNet mimarisi.....	47
Şekil 2.7. AlexNet mimarisi.....	47
Şekil 2.8. GoogleNet mimarisi.....	48
Şekil 4.1. BreakHis 400x veri kümesinin sınıfları; a) iyi huylu, b) kötü huylu.....	52
Şekil 4.2. Önerilen modelin genel mimari yapısı	55
Şekil 4.3. ResNet-X modelinin mimari yapısı.....	58
Şekil 5.1. ResNet modellerinin 1000 özellikli eğitim ve test başarı grafikleri; a) ResNet-18, b) ResNet-50, c) ResNet-101.....	61
Şekil 5.2. ResNet modellerinden elde edilmiş 1000 özellikli karmaşıklık matrisleri; a) ResNet-18, b) ResNet-50, c) ResNet-101.....	61
Şekil 5.3. ResNet modellerinden elde edilmiş 2 özellikli karmaşıklık matrisleri; a) ResNet-18, b) ResNet-50, c) ResNet-101.....	62
Şekil 5.4. Önerilen yaklaşımda, softmax ve makine öğrenme yöntemleri ile gerçekleştirilmiş analiz sonuçları; a) Karmaşıklık matrisi, b) ROC eğrisi.....	63

Şekil 5.5. ResNet modellerinin 1000 özellikli eğitim-test kayıp grafikleri; a) ResNet-18, b) ResNet-50, c) ResNet-101.....	64
Şekil 5.6. Makine Öğrenme Yöntemleri Sonuçları-1.....	64
Şekil 5.7. Makine Öğrenme Yöntemleri Sonuçları-2.....	65
Şekil 5.8. Makine Öğrenme Yöntemleri Sonuçları-3.....	65
Şekil 5.9. EYK çıktısı.....	66
Şekil 5.10. ROC eğrisi.....	66



ÇİZELGELER

Çizelge 5.1. ResNet modellerinin eğitimi sürecinde tercih edilmiş parametre değerleri.....	60
Çizelge 5.2. ResNet modellerinden elde edilmiş karmaşıklık matrislerin (1000 özellikli) metrik sonuçları.....	63
Çizelge 5.3. Önerilen yaklaşımın analiz sonuçları	64



SİMGELER VE KISALTMALAR

2B	İki Boyutlu
3B	Üç Boyutlu
ALS	Amyotrofik Lateral Skleroz
BDTS	Bilgisayar Destekli Teşhis Sistemi
BÇS	Bulanık Çıkarım Sistemi
BT	Bilgisayarlı Tomografi
DDİ	Doğal Dil İşleme
DÖ	Derin Öğrenme
DSA	Derin Sinir Ağı
DVM	Destek Vektör Makineleri
EKG	Elektrokardiyografi
ESA	Evrişimli Sinir Ağları
EYK	En Yakın Komşuluk
KAA	Karar Ağacı Algoritması
LDA	Lineer Diskriminant Analizi
LR	Lojistik Regresyon
MÖ	Makine Öğrenmesi
MR	Manyetik Rezonans
MRG	Manyetik Rezonans Görüntüleme
Nİ	Nesnelerin İnterneti
TB	Tam Bağlantılı
TBA	Temel Bileşen Analizi
TSA	Tekrarlayan Sinir Ağları
UKSB	Uzun Kısa Süreli Bellek
US	Ultrason
YSA	Yapay Sinir Ağları
YZ	Yapay Zekâ

1. GİRİŞ

Meme kanseri, en fazla tanı konulan kanser türü olmakla beraber yoğun olarak kadınlarda görülmektedir. Dünya genelinde her yıl ortalama 2 milyondan fazla kadına meme kanseri tanısı konulmakta olup bu tanılarının yaklaşık 685 bini ölümlle sonuçlanmaktadır. Kadınlarda meme kanseri her 4 kanser vakasının birinden ve her 6 kanserin neden olduğu yaşam kayıplarından birine sebep olmaktadır. Son yıllarda meme kanserinin erken tanı ve tedavisinden dolayı hayatını kaybeden insan sayısında düşüş yaşansa da vaka sayısı oldukça yüksektir (Ortega-Martorell ve ark., 2022).

Genel olarak bu hastalığı önleyici davranışlar ve tarama programları gibi çeşitli prosedürler, meme kanserine yakalanma durumunun mümkün olduğunca en aza indirilmesine neden olmuştur. Erken tedavinin uygulanması da bu hastalığın azaltılması açısından çok önemlidir. Şu anda, dünya çapında meme kanseri kontrolünü sağlamak için uygun kılavuzların ve yaklaşımların hazırlanmasından sorumlu olan kurum küresel meme sağlığı girişimidir.

Meme kanseri, erkeklere nazaran kadınlarda daha sık görülmekle beraber dünya geneli kanser ölümlerinin başında gelmektedir. Küresel olarak meme kanserine yakalanma durumu ülkelerin gelişmişlik sürecine göre değişiklik göstermektedir. Asya ve Afrika ülkelerinde ölüm oranları gelişmiş Avrupa ülkelerine göre daha fazladır. Düşük gelirli ve birçok orta gelirli ülke kadınlarında bu durum yoğun bir şekilde yaşanmaktadır.

Yapılan araştırmalara göre her sekiz kadından biri meme kanseri hastalığına yakalanacaktır. Kansere yakalanmayı engellemek adına erken teşhis hastalığın sayısını önemli ölçüde azaltacağı kanıtlanmıştır (Waks ve Winer, 2019). Bu nedenle meme kanseri kadınların düzenli olarak tarandığı birkaç kanser türünden biridir. Böylece kanserler klinik belirtiler ortaya çıkmadan önce tanı konulabilir duruma gelmiştir. Yapılan önemli bir araştırmaya göre düzenli tarama sonucunda meme kanseri hastalığı ölümlerinde yaklaşık %20 den fazla azalma olduğu görülmüştür. Bu nedenle erken teşhis önemli bir etkiye sahiptir. Son on yılda, daha önceden tespit edilmemiş kanser yakalamadaki üstün yeteneği nedeniyle dijital mamografi için yeni altın standart olarak Üç Boyutlu (3B) görüntüleme tekniği ortaya çıkmıştır.

Meme kanseri hücreleri iyi huylu ve kötü huylu olarak iki gruba ayrılmaktadır. İyi huylu kanser hücreleri, yavaş büyür ve vücuttaki diğer organlara yayılmayan normal hücrelerden oluşmaktadır. Kötü huylu kanserli hücreler ise daha agresif hücrelerden

oluşmaktadır. Bu hücreler bulundukları bölgelerden vücudun diğer bölgelerine yayılırlar (Khan ve ark., 2019). Kötü huylu kanser hücreleri zamanında tedavi edilmediği takdirde bu hücreler hasta için ölümcül sonuçlar doğurabilir. Bu sebeplerden ötürü erken tanı ve tedavi ölüm oranlarını düşürerek hastaların hayatta kalmaları için büyük önem taşımaktadır.

İnsan kaynaklı tanı sorunları, hastalığın tedavi süreci hakkında zaman zaman olumsuz etki bırakmaktadır (Mahmood ve ark., 2020). Bunun sonucu, doğrudan insan hayatını etkilemekte, sosyal ve ekonomik yönden de ciddi problemlere sebebiyet vermektedir. Bu sebeplerle tıp uzmanlarına yardımcı olabilecek, insan kaynaklı hataları minimuma indirgeyecek bir bilgisayar temelli tanı sistemi ile kanserle olan mücadele de hastalığın erken tanı ve tedavisinde etkin rol oynamaktadır. Bundan dolayı, günümüzde en gelişmiş teknolojilerden olan Yapay Zekâ (YZ) temelli yöntemler; veri analizi, sınıflandırma, nesne tanıma ve karar verme gibi işlemleri başarıyla gerçekleştirilebilmektedir. Derin Öğrenme (DÖ) yöntemleri kullanılarak klinik ve radyoloji alanında karar destek sistemleri oluşturmak adına çok sayıda araştırma yapılmaktadır (Çalışkan ve ark., 2022a; Shaikh ve ark., 2021; Spänig ve ark., 2019; Zerouaoui ve Idri, 2021; Çalışkan, 2023b). DÖ, bu teknolojinin alt dallarından biridir. Hastalığın tanı aşamasında kullanıcı tarafından yapılan kontrol ve ardından gerçekleştirdiği çıkarımları otomatik hale getirerek veri setlerindeki niteliklerin tespiti aşamasını ortadan kaldırır.

Bilgisayar Destekli Teşhis Sistemi'nin (BDTS) benimsenmesinde ki en önemli engellerden biri, çoğu görüntüleme modalitesinin titizlikle test edilmiş olan ve onaylanmış olması ve oldukça katı bir tıbbi yönetim ve uygulama modeli içinde mevcut olmasıdır. Görüntüleri anlamlandırıp yorumlamaya yönelik çoğu DÖ sistemi mevcut çalışmalar ile ilişkilendirilmiştir. YZ tabanlı sistemleriyle birlikte bu en iyi uygulamaların birlikte geliştirilmesi için benzersiz bir fırsat sunmaktadır. DÖ modelleriyle teknolojiyi sorunsuz bir şekilde entegre edecek görüntüleme yöntemlerinden biri olacağı öngörülmektedir (Dargan ve ark., 2020; Oza ve ark., 2022).

Meme kanseri taramasının yorumlanmasına özgü karşılaşılan başka bir zorlukta kötü huylu hücrelerin yaygınlığının düşük olmasıdır. Öte yandan kötü huylu zenginleştirilmiş eğitim verilerinin kullanılması, kanser tarama programlarında yaygın bir sorun olarak ta görünmektedir (Debelee ve ark., 2020; Stachs ve ark., 2019).

DÖ, birçok görüntü tanıma uygulamasında güçlü performans göstermiştir (Krizhevsky ve ark., 2017; Tsochatzidis ve ark., 2019; Çalışkan, 2022). Son dönemlerde

patolojideki diğer uygulamaların yanı sıra lenf düğümlerinde meme kanseri iyi huylu mu kötü huylu mu olduğuna dair DÖ tabanlı algoritmaları geliştirmiştir (Debelee ve ark., 2020; Madani ve ark., 2022; Dammu ve ark., 2023). İlk bulgular, bazı algoritmaların, dijital görüntülerde tek tek kanser odaklarını saptamak için bir patoloğun duyarlılığını bile aşabileceğini düşündürmektedir. Ayrıca, DÖ algoritmaları, doğası gereği özel olarak eğitildikleri görevle bağlı kullanılmaktadır. Bu algoritmaların güçlü yanlarını ve zayıflıklarını anlamaya başlamış olsak da, bu tür algoritmaların potansiyel klinik faydası şimdiye kadar tam olarak incelenmemiştir. Doğru bir algoritma tek başına patoloğlara mutlaka yardımcı olmayacak veya klinik yorumlamayı iyileştirmeyecek olsa da, bu faydalar, algoritma tahminlerinin klinik süreçlere dikkatli ve uygun bir şekilde entegrasyonu yoluyla elde edilebilir (Krizhevsky ve ark., 2017).

Radyografik görüntüleri kullanarak çalışan makine öğrenimi ve görüntü tanıma algoritmaları özel yazılımlardır ve teşhis özelliklerine sahiptir. Bu sistemler daha sonra test görüntülerinde (ör. görünmeyen veya eğitimde kullanılmayan) eğitildikleri görüntüleme modellerini tanıyarak çeşitli hastalıkların tespiti ve teşhisine katılmalarına olanak tanır. Bu sistemler, çok çeşitli tümör tiplerinin gelişmiş tespiti ve teşhisine yardımcı olarak onkoloji alanında çok faydalı olma potansiyeline sahiptir (Dominique ve ark., 2022). Son zamanlarda, makine öğrenimindeki heyecan verici yeni gelişmeler, özellikle de DÖ nedeniyle bu alandaki araştırmalar daha olumlu bir yöne doğru ilerlemektedir (Raaj, 2023; Abunasser ve ark., 2022).

DÖ, makine öğreniminin sürekli gelişen bir alt araştırma alanı olmuştur. Son dönemlerde DÖ yöntemlerindeki bu hızlanmanın arkasındaki ana nedenler, insan zekâsından ilham alan daha gelişmiş bilgisayar algoritmalarının kullanılabilirliğinin yaygınlaşması, büyük veri kümelerini işlemek ve depolamak için çağdaş donanım teknolojisindeki güncellemeler ve büyük miktarda etiketlenmiş verinin erişilebilirliğinin artmasıdır (Koh ve ark., 2022). Bu algoritmaları daha iyi bir hassasiyetle eğiterek daha verimli sonuçlar alınabilir. BDTS'ye yönelik bu devrim niteliğindeki ve son teknoloji yaklaşımı, grafik, genetik, tıp, otomotiv endüstrisi, internet, radyoloji ve görüntüleme bilimleri dâhil olmak üzere geniş bir uygulama yelpazesine sahiptir (Madani ve ark., 2022; Zerouaoui ve ark., 2022).

Makine öğreniminin geleneksel yaklaşımında, tıbbi görüntülerdeki uzmanları, daha sonra çalışmaları geliştiren özellik mühendisliği için kullanılacak görüntü açıklamaları için gereklidir. Böylelikle DÖ de araştırmacıların dijital meme tomosentezi, mamografi, Manyetik Rezonans Görüntüleme (MRG) ve Ultrason (US)

görüntüleme modaliteleri kullanılarak elde edilen ham tıbbi görüntülerden segmentasyon, özellik çıkarma, görüntü sınıflandırma ve görüntüyü algılamaya yardımcı olmak için önemli ölçüde gelişmeler sağlandığı yapılan araştırmalarda görülmüştür (Mohamed ve ark., 2022; Botlagunta ve ark., 2023).

Derin Sinir Ağı (DSA) tekniğini kullanan memelerin cerrahi müdahale gerektirmeyen termaline nispeten az sayıda çalışma katkıda bulunmuştur (Ibrokhimov ve Kang, 2022). Literatürde bulunan sınırlı kaynaklar göz önüne alındığında, bu sorun üzerindeki çalışmalar henüz başlangıç aşamasındadır. Çalışmalar başlangıç aşamasında olduğundan meme kanserindeki erken teşhisi sağlanması için uzman hekimler tarafından güvenilir, cerrahi müdahale gerektirmeyen teknolojinin ön planda tutulduğu BDTS uygulamaları geliştirmek için büyük çabalar gerekmektedir. Bu, termal görüntüleme ve meme kanseri tespiti için DÖ ile ilgili önceki, güncel ve gerekli gelecekteki araştırmaların büyük önem taşıdığı düşünülmelidir. Potansiyel araştırmalar yönlendirilebilir ve bu çalışmada tanımlanan önemli sorunlara odaklanabilir.

Günümüzde 40 yaşının altındaki sağlıklı kişilerde ortalama her 3 yılda bir muayene edilmesi, 40 yaşın üzerindeki kişilerde her yıl kontrollerin yapılması önerilmektedir. Bu durum genetik durumların haricinde kullanılmaktadır. Meme kanserinde kendi kendine muayene de tanısal sürecin bir aşaması olsa bile fiziki muayenenin yanında deneyimli cerrahlar tarafından da radyolojik tetkikler kullanılarak görüntü işleme tekniklerine de başvurulması gerekmektedir (Ueda ve ark., 2019).

Son dönemlerde teknoloji ile beraber gelen tıbbi görüntülemelerdeki bazı sorunları çözmek için Makine Öğrenmesi (MÖ) yöntemlerinin kullanılma becerisinde önemli mesafelerin alındığı yapılan araştırmalarda görülmüştür (Fatima ve ark., 2020; Vaka ve ark., 2020). Basit BDTS ile mamografi de yıllardır mevcutta kullanılsa da bu tür sistemler geleneksel olarak fayda anlamında kısır kalmıştır. Buna karşılık, geleneksel mamogramlardaki kötü huylu hücrelerin eğitimli radyologlar düzeyinde, hatta onlardan daha iyi tespit etmek için yeni DÖ yöntemlerinin geliştirmesi gösterilmiştir (Hamed ve ark., 2020; Shahidi ve ark., 2020).

YZ tabanlı yaklaşımlar insanın duygu ve düşünce özelliklerini MÖ yöntemleriyle sanal ortama aktarılmasını sağlayan, insanüstü kararlar vermeyi hedefleyen teknik yöntem ve modellerden oluşmaktadır (Nassif ve ark., 2022). DÖ ve MÖ, YZ'ye bağlı olarak gelişim göstermektedir. Sınıflandırma, bölütleme gibi çeşitli işlemleri gerçekleştirebilen YZ yaklaşımları sağlık sektöründe hastalıkların tanı ve tedavilerinde kullanılmaya başlamıştır (Emmert-Streib ve ark., 2020). Literatürde YZ

destekli birçok tanı sistemi geliştirilmiştir (Çalışkan ve ark., 2022a). Aljuaid ve ark. (2022), “BreakHis” veri kümesini kullanarak DÖ modelleri ile analizler gerçekleştirdi. “BreakHis” veri kümesini kullanarak DÖ modelleri ile analizler gerçekleştirdi. ResNet-18, İnceptionV3 ve ShuffleNet modelleriyle sınıflandırma girdi görüntülerini sınıflandırdılar. Deneyisel analizlerde ResNet modeliyle en iyi başarıyı sağladılar ve %99,7 genel doğruluk başarıları elde ettiler. Zahoor ve ark. (2022), meme kanseri türlerini sınıflandırabilmek için DÖ modelleri ile birlikte meta-sezgisel optimizasyon yöntemini birlikte kullandılar. Analizlerden çıkardıkları öznelilikleri sınıflandırmak için çoklu MÖ yöntemlerini kullandılar. Açık erişimli üç farklı veri kümesini kullanarak gerçekleştirdikleri analizlerde sırasıyla; %99.7, %99.8 ve %93.8 doğruluk başarıları elde ettiler. Mostafa ve ark. (2018), meta-sezgisel yöntemleri özellik seçim işlemlerini gerçekleştirmek için önerdikleri yaklaşımda kullandılar. Meme kanseri türlerini sınıflandırma işlemlerinde iki veri kümesi kullandılar ve özneliliklerin çıkarımında artık bloklara dayalı bir Evrişimli Sinir Ağları’nın (ESA) modeli geliştirdiler. Analiz sonuçlarına göre iki veri kümesi için elde ettikleri genel doğruluk başarıları sırasıyla, %98,32 ve %98,88’di. Thilagaraj ve ark. (2022), meme kanseri türlerini sınıflandırma işleminde radyal tabanlı ESA modelini kullandılar. Özneliliklerin indirgenmesi işleminde yapay balık okulu optimizasyon yöntemini kullandılar. Sınıflandırma sürecinde elde ettikleri en iyi genel doğruluk başarıları %98,66’ydı.

Çalışmamızda meme kanseri veri kümesini kullanarak türlerine göre sınıflandırabilen, DÖ tabanlı bir model önerilmiştir. Önerilen yaklaşım;

Tıp uzmanların daha kolay karar verebilmesini sağlamak,

Zamandan kazanç ve performanstan artış sağlayabilmek,

Eş zamanlı birçok girdi verisini karar destek sistemi tabanlı sonuçlandırabilme, vb. katkılar sağlamıştır.

1.1. Radyolojik Tanı Yöntemleri

Tıpta görüntüleme yöntemleri vücut içinin resimlerini gösterir. Görüntüleme yöntemlerinden bazıları; mamografi, Manyetik Rezonans (MR) ve US, etkin bir şekilde hastanın tanı-tedavi sürecinde kullanılmaktadır (Çalışkan ve ark., 2022a ; Ayana ve ark., 2022). Meme kanserinin teşhisinde birçok görüntüleme yöntemi kullanılır (Freeman ve ark., 2021). Hangi meme kanseri taramasının yapılmasının uygun olduğunu uzman hekimler ile görüşülmesi gerekmektedir.

Memelerin tıbbi görüntüleri, tarama yöntemlerini oluşturmaktadır. Oluşan bu görüntülerin anlamlandırılması normal koşullarda radyologlar ve doktorlar gibi uzman bireylerden tarafından gerçekleştirilmektedir. Yapılan araştırmalarda termogramların tanısasal olarak düşük doğruluğunun, bu kritik görüntüleri yorumlamadaki düşük kriterli teknik yetenek ve uzmanlığa atfedildiğini göstermektedir. Birçok hastalığın ortaya çıkmasında insan emeğinin daha sınırlı olduğu araştırmacıları ve tıp personelleri tarafından meme termografisine dayalı teşhisi kolaylaştırmak ve böylelikle oluşabilecek hataları en aza indirmek için BDTS teknolojilerini kullanmaya yönlendirmiştir (Zerouaoui ve ark., 2022; Shah ve ark., 2022). Bu sebepten ötürü görüntüleri otomatik olarak normal ve anormal olarak kategoriye ayırabilen teknolojiye ihtiyaç duyulmaktaydı. Bu gereklilik göz önüne alındığında, tıbbi görüntüleri sınıflandırmak için bilgisayar tabanlı çözümler bulmaya yönelik araştırmalar sürekli olarak büyümektedir (Zahoor ve ark., 2022; Dar ve ark., 2022).

Meme kanseri teşhisi sürecinde birçok hastane de tarama programları uygulanmakta ve meme kanseri vakalarının da artması uzman hekimlere ciddi iş yükü getirmektedir. Artan maliyetler ve zaman kaybı ile birlikte özellikle son yıllarda teknolojinin kullanılması kaçınılmaz hale gelmiştir. Geleneksel bilgisayar tabanlı teşhis sistemleri artık güncel olarak ihtiyacı karşılayamamaktadır. Son yıllarda gelişen YZ sistemleri insan iş yükünü azaltmakta olup ve daha başarılı sonuçlar vererek diğer alanlarda olduğu gibi sağlık alanında da adından sıkça söz ettirmektedir (Sheth ve Giger, 2020; Shah ve ark., 2022; Zheng ve ark., 2020).

YZ sistemleri insan duygu ve düşünme yetilerini makine ortamlarına aktarılmasını öngören, insanüstü kararlar vermeyi amaç edinen teknik, yöntem ve modellerden oluşmaktadır (Sechopoulos ve ark., 2021; Çalışkan ve ark., 2022a). YZ, MÖ ve DÖ gibi alt katmanlardan oluşmaktadır. Bilgisayar görüşü, regresyon, sınıflandırma, bölütleme gibi birçok işlemi gerçekleştirebilen bu yaklaşım, hastalıkların tanı ve tedavi süreçlerinde de kullanılmaya başlamıştır (Janiesch ve ark., 2021; Emmert-Streib ve ark., 2020; Carter ve ark., 2020).

Makine öğreniminin bir alt kümesi olan DÖ doğrudan görüntü verileri üzerinde çalışır ve böylece insan müdahalesi olmadan hastalığın tanısı için uygun özellikleri tanır (Houssein ve ark., 2021). Bilgisayarla öğrenme 2012 yıllarında ESA gelişmesinden sonra, DÖ ile çok daha gelişim göstermiştir (Krizhevsky ve ark., 2017). O dönemden beri DÖ teknikleri ve özellikle ESA'lar, tıbbi görüntü ve analizlerde yaygın bir şekilde uygulanmış ve meme radyolojisinde geleneksel sistemleri büyük oranda geliştirmiştir.

Genellikle meme görüntüleme, mamografi, US, MR ve Bilgisayarlı Tomografi (BT) ile gerçekleştirilir.

1.1.1. Mamogram


Meme kanseri tanısında kullanılan mamografi en yaygın radyografik görüntüleme yöntemidir (Khamparia ve ark., 2021; Loizidou ve ark., 2022; Çalışkan ve ark., 2022a). Meme kanserinin erken, daha olgunlaşmamış küçük bir yumru iken ve hissedilmeden önce tespit edebilir ve bu durumda tespit edilmesi tedavi için en kolay zaman olarak değerlendirilir (Saber ve ark., 2021). Mamogramlar, meme kanserinin tespitinde genellikle ilk aşama olarak kullanılırlar. Memede anormal alanları gösterir ancak anormal bölgenin kanserli olup olmadığını kanıtlayamazlar. Tıp uzmanlarının anormal bölge için daha fazla test gerektirip gerektirmediğine karar vermelerine yardımcı olabilirler.

Mamografi taraması, meme kanseri teşhisi için dünya geneli birçok ülkede kullanılmaktadır (Ahmed ve ark., 2020). Başlangıçta kadın sağlığını iyileştirmek ve meme kanseri yükünü azaltmak için evrensel bir başarı olarak övülen mamografi taramasının yararları ve zararları geçtiğimiz yıllarda hararetli bir şekilde tartışma konusu olmuştu (Dar ve ark., 2022). Mamografi taramasının en temel faydası meme kanserine bağlı ölümleri azaltmaktır. Göreceli azalmalar, randomize çalışmalarda yaklaşık %15 ile %25'ten, gözlemsel çalışmaların meta-analizlerinde daha yeni tahminlere göre %13 ile 17 arasında değişmektedir (Khan ve ark., 2019). 2007 İngiltere nüfus verileri kullanılarak, 50 yaşından itibaren 20 yıl boyunca iki yılda bir mamografi taramasına davet edilen 1000 kadın için, 2 ila 3 kadının meme kanserinden ölmesi engellenmiştir (Warner, 2011; Hofvind ve ark., 2015). Tüm nedenlere bağlı mortalite değişmez. Mamografi taramasının en büyük zararı meme kanserinin aşırı teşhisidir. Tahminlere göre, göreceli aşırı teşhis miktarı (in situ duktal karsinoma ve invaziv kanser dâhil) %31'dir. Bu, 50 yaşından itibaren 20 yılda bienal mamografi taramasına davet edilen her 1000 kadın için 15 kadının aşırı tanı almasına neden oluyor (Moss ve ark., 2006). Kadınlar, mutlak etki büyüklükleri kullanılarak anlaşılır bir şekilde mamografi taramasının yararları ve zararları konusunda tutkusuz bir şekilde bilgilendirilmelidir. Kaynakların sınırlı olduğu dönemlerde tarama hizmetlerinin elde ettiği çıktıların dikkatler incelenmesi ve zararlar noktasında birbirleriyle karşılaştırılması gerekmektedir.

Meme kanserinin preoperatif deęerlendirmesinde klinik tanı, mamografi ve meme ultrasonografisinin doęruluęu erken tanı için gereklidir (Zhu ve ark., 2021). Aynı zamanda, neoadjuvan kemoterapiye veya hastalar genellikle ilk cerrahi müdahaleden sonra kaçarken tümör nüksü insidansını azaltmak için net cerrahi sınırlara sahip tek bir cerrahi müdahaleye izin vermek için doęru tedavi öncesi planlamaya izin vermektir.

Konvansiyonel meme mamografisi tüm dünyada meme kanseri tanısında rutin görüntüleme teknikleri olarak kullanılmaktadır (Raaj, 2023). Mamografik kanserin saptanması duyarlılığı yüksektir, ancak meme kanserleri glandüler ve fibröz elementlerinkine benzer bir radyografik zayıflamaya sahip oldukları için radyografik olarak yoğun memeleri olan kadınlarda azalır (Moloney ve ark., 2020). Mamografinin indeks kanser aralıklarına duyarlılığı %63'ten %98'e ve yoğun göęüslerde %30 ila %48'e kadar düřtüęü rapor edilmiştir (Liu ve ark., 2022). Dolayısıyla mamografi ile meme kanseri teşhisinin doęruluęunu azaltmaktadır.

Mamogram teknięinde X ışınları memeden gönderilir ve dijital bir X-ışını dedektörü tarafından toplandıktan sonra, memenin İki Boyutlu (2B) görüntüsünü oluşturur (Dar ve ark., 2022). Makine, 2 plakadan oluşur ve bu plakalar memeyi düzleştirerek dokuyu birbirinden ayırır ve daha az radyasyonla daha iyi görüntü elde eder. Uzman hekim elde ettięi bu görüntü ile yapmış olduęu incelemede meme dokusunda bulunan normalin dışında bir durumun olup olmadığı daha net bir şekilde anlaşılır. Hızlı ve kolay bir tekniktir. Ayrıca, 3 Boyutlu (3B) mamogramlar ile standart 2B mamogramlar arasındaki sonuçları daha iyi karşılařtırmak için devam eden çalışmalar bulunmaktadır. Şekil 1.1' de verilmiş olan soldaki mamogram görüntüsü, okun gösterdięi yerde bir anormallięi gösteren 3B bir görüntüdür. Sağdaki 2B görüntüde anormallik daha az belirgindir.



Şekil 1.1. Mamogram görüntüsü (Zhang ve ark., 2018)

1.1.2. Ultrason Görüntüleme

Ultrason görüntüleme yöntemi, meme görüntüleme de çok yararlı bir araç haline gelmiştir. İlk olarak ABD 1950’lerde uyarlanan radar teknikleri kullanılarak tanıtıldı (Dempsey, 2004). Sonraları meme görüntülemeye basit katı kitleleri ayırmak için kullanıldı (Debelee ve ark., 2020).

Ultrason son yıllarda, tıbbi görüntüleme tekniklerini geleneksel radyolojiden çok öteye taşıdı (Jiménez-Gaona ve ark., 2020; Nassif ve ark., 2022). Bu ileri gidiş düşük maliyetin ve kullanımın kolaylığı ile birleşince US görüntüleme tekniği radyologlar arasında yaygın olarak kullanılmayı yaygın hale getiriyor. US tekniği, derin dokular uygulanan penetrasyon için çok önemli bir yeteneği iyi bir çözünürlükle birleştirir. Ancak kemik veya gazın üzerini kaplayanlar istisna tutulabilir. Saniyede yüzlerce ve binlerce kareye kadar olan gerçek zamanlı görüntülerin ve biyopsilerin yönlendirilmesini sağlamaktadır ve aynı zamanda dokuların mekanik olan özelliklerinin prosedürlerin doğruluğuna büyük ölçüde yardımcı olmaktadır. Ultrasonun lokal olarak enerji biriktirme yeteneği, doku ablasyonu, vücutta ilaç dağıtımına yönelik doğal engellerden penetrasyonu artırma ve taşıyıcı mikro ve nanopartiküllerden ilaç salınımını tetiklemeyi kapsayan lokalize müdahale potansiyelini beraberinde getirir. Mikro kabarcıklarla kontrast maddelerin kullanımı doku perfüzyonunu izlemeyip miktarının belirlenme yeteneğini beraberinde getirmekte olup, ligandla dekore edilmiş olmakla beraber mikro kabarcıklarla hedeflemesi, US moleküler görüntülemeyi elde etme özelliğini getirir. US,

genel olarak modern tıpta en yoğun kullanılan görüntüleme yöntemidir ve büyümeye aynı zamanda gelişmeye devam edecek gibi görünmektedir.

1960'lerden beri dünya da yaygın olarak kullanılmış ve günümüzde aktif olarak kullanılmaktadır (Haria ve ark., 2022). Bu yönüyle US görüntüleme, iyi bilinen bir alan olduğuna inanılmaktadır. US görüntülemenin pratikte dünya çapındaki yıllık kullanımı şimdiden milyarları aşmıştır ve Almanya, Norveç, İzlanda ve Avusturya gibi bazı ülkelerde tüm hamile kadınlar yıllardır US ile taranmaktadır (Seo ve Kim, 2017). Endüstride, 2000'lerin başından beri yalnızca taşınabilir sistemler mevcut değildi, aynı zamanda 2010'ların başında tablet PC'lerle işbirliği yapan kablosuz US görüntüleme dönüştürücüleri de piyasaya sürüldü (Van Sloun ve ark., 2019). Buna göre, tıpta US, genel izleyiciler için nispeten düşük teknoloji ve modası geçmiş bir araştırma alanı olarak kabul edildi.

Tıbbi US, son 20 yıldır en fazla araştırılan alanlardan biri olmuş ve tanınal US'de çok sayıda ilerleme göstermiştir (Ouahabi ve Taleb-Ahmed, 2021). US görüntüleme, elastografi, US kontrast ajan görüntüleme, süper çözünürlüklü görüntüleme ve 2B dizi dönüştürücü dikkat çekicidir (Khan ve ark., 2020). Belirli bir dokunun elastik özelliği, belirli bir fibröz tümörün kanser teşhisi ve stent implantasyonu sırasında arterdeki hassas plakların değerlendirilmesi için kritik olabilir (Huang, 2020). Elastic özellikler genel olarak US'de tam olarak anlaşılmamaktadır. Elastisitenin niceleyici ölçümü için hedef doku üzerinde kontrollü deformasyon kuvveti sağlayan radyasyon kuvveti, US görüntüleme transdüseri ile gerçekleştirilmiş ve onlarca mikrometreye kadar lokal doku pozisyon takibi sağlayan benek takibi algoritması geliştirilmiştir. Bu teknolojiler daha sonra çerçevesi 10.000/s'ye ulaşabilen yüksek çerçeveli geç US görüntüleme sistemi ile birleştirildi ve yüksek çözünürlüklü kantitatif elastografi sunuldu.. Öte yandan, yukarıda tanıtılan yüksek çerçeveli bir geç sistemle kan damarındaki mikro kabarcıkların basitçe izlenmesiyle süper çözünürlüklü görüntüleme elde edildi (Krizhevsky ve ark., 2017). Tek bir mikro-kabarcık, çözünürlüğü US sisteminin nokta yayılma fonksiyonundan birkaç kat daha yüksek olan bir saçıcı olarak sayılabileceğinden, ortaya çıkan görüntüler bize derin yerleşimli organda mükemmel damar ağları gösterebilir. Bu yeni US görüntüleme teknolojilerini 3B olarak genişletmek için 2B dizi dönüştürücü gereklidir, böylece mikro-işlenmiş dönüştürücüler de geliştirilmiştir (Chen ve ark., 2020).

Meme ultrasonu, memenin iç yapısının bilgisayar ortamında vücut hareketlerinin görüntülenebilecek şekilde resminin oluşturulmasına denir (Zhang ve ark., 2021).

Ayrıca US, tıp uzmanlarının göğüs bölgesindeki kan akışının da görülmesini sağlar. US, tek başına meme kanseri taraması olarak kullanılmaz. Genellikle genç hastalarda mamogram ile görünmeyebilecek bir anormalliğin olduğu bir durum hissedilirse (iyi huylu veya kötü huylu), bu durumu anlamamanın en iyi yolu ultrason görüntüleme yöntemidir. Aynı zamanda US mamografiden farklı olarak görüntüdeki dokular birbirinin üzerine binmediğinden dolayı tanı hatasını engellediğinden mamografiyi destekleyen bir medikal görüntüleme yöntemi olarak kullanılır.

Transdüser cihazıyla memeye sürülen jel sürülen memenin sorunlu kısmı üzerinde cihaz hareket ettirilir. Gönderilen bu ses dalgalarını dönüştürülerek vücut dokularının üzerinde yansıyan ses hissedilerek sanal ortamda bir görüntü oluşturulur. Oluşturulan bu görüntü genellikle ağrısız ve 30 dakika içinde tamamlanır. Transdüser cihazı deri üzerinde hareket ettirilirken ekranda gerçek zamanlı görüntüleme oluşturur.

Meme US radyasyon riski taşımadığından hamileler için bir risk oluşturmazlar. Ayrıca obez ve iri göğüslü bireylerin US test sonuçlarındaki doğruluk oranı daha az olabilmektedir. US, meme kanserinin en erken dönemine ait olan küçük kireç oluşumlarını göstermediğinden tarama yaparken tek başına kullanılmadığı durumlar olabiliyor. Memenin iyi huylu hastalıkları da şüpheli olarak gösterebildiği için zaman zaman biyopsi de gerekebiliyor.

Soldaki normal meme parankiminde sıvı dolu test görüntüsü, sağdaki ultrason ile tespit edilmiş ok ile gösterilen başlangıç yeri yeni olan meme kanseri görüntüsü Şekil 1.2' de sunulmuştur.



Şekil 1.2. Meme kanseri görüntüsü (Wang ve ark., 2021)

1.1.3. Manyetik Rezonans Görüntüleme

MR genellikle hastalığın tespiti için kullanılır (Eskreis-Winkler ve ark., 2021). Tespit edilen hastalığın daha sonra tedavisinin takibi için kullanılır. Gelişmiş

teknolojiyle canlı dokuları oluşturan suda bulunan protonlardaki değişiklikleri tespit edebilen bir yapıya sahiptir. Zararlı radyasyon kullanmaması sağlık açısından kullanımını arttırmaktadır. Günümüzde tıbbi görüntüleme yöntemlerinin en yoğun kullanılan araçlarından biridir. Gelecekte ise, bilgisayar biliminin daha çok gelişmesiyle çok daha fazla mesafe alacağı düşünülmektedir.


O günlerde dünyanın çeşitli yerlerinde çeşitli gruplar tüm vücut MRG sistemlerini geliştiriyordu. İngiltere'deki Hammersmith Hastanesi'nde, süperiletken bir mıknatıs ile 0.15 T manyetik alanda bir projeksiyon rekonstrüksiyon yöntemi kullanılarak bir sistem inşa edildi ve birçok klinik görüntü rapor edildi (Krizhevsky ve ark., 2017). 0.35 T'lik statik manyetik alan, önceki çalışmalarda bildirilenin iki katından daha büyüktü ve MRG'nin manyetik alanında bir artışı tetikledi. MR görüntüsünün sinyal-gürültü oranının statik manyetik alan kuvvetiyle orantılı olarak artmasından kaynaklanmaktadır.

Tıbbi araştırmalarda kullanılmak üzere MRG'nin geliştirilmesi, özellikle potansiyel olarak tehlikeli iyonlaştırıcı radyasyona maruz kalmanın önlenmesiyle, teşhis alanında büyük bir ilerleme sağlamıştır (Madani ve ark., 2022). Düşen maliyetler ve daha iyi erişilebilirlik ile MRG kullanımı klinik uygulamada her zamankinden daha yaygın hale geliyor. Bu görüntüleme yönteminin ve onun çoklu uygulamalarının altında yatan ilkeleri anlamak, kullanımının yararlarını ve sınırlamalarını değerlendirmek için kullanılabilir ve klinik karar verme sürecini daha da bilgilendirir.

Meme kanserini tespit etmek için de kullanılabilir ve özellikle yüksek riskli hastalarda önerilen tarama için kullanılan kapsamlı bir görüntüleme tekniğidir (Mridha ve ark., 2021). Bu tarama yöntemiyle hem iyi huylu hem de kanserli tümörleri tespit etmeye yarar.

Meme kanserinin tespit edilmesi için kullanılan en hassas yöntemdir. Tanı ve tedavideki rolü gelişmeye devam etmektedir. %90 üzerinde bir doğruluk oranına sahiptir (Menezes ve ark., 2014). Uzman radyologlara göre MRG, mamogram ve US çalışmaları birbirini tamamlayan vazgeçilmez meme kanseri tanı yöntemleridir. Kullanım alanları, meme kanserinin evrelendirilmesi, yüksek risk altındaki kadınlarda meme kanseri taraması ve neoadjuvan kemoterapiye verilen yanıtın değerlendirilmesini sağlar (Mann ve ark., 2008; Woodard ve ark., 2006). Meme MR'sine ait öğrenme eğrisine ait veriler günümüzde hala eksik olsa da yapılan bazı çalışmalar ile radyologların kanser tespit performansı önemli düzeyde artmıştır (Warner ve ark., 2011).

MR görüntüleme radyasyon kullanmanın aksine, radyo dalgaları vücutta doğal olarak bulunan hidrojen atomlarının yeniden hizalanmasını sağlar. Bu dokuların kimyasal yapılarında bir değişiklik olmaz. Tarama cihazı da bu enerjiyi yakalayarak bir bilgisayar görüntüsü haline getirir. MRG meme kanseri şüphesinin yanı sıra meme kanseri olan bireyler için kanserin boyutunu ölçmek, memedeki varsa diğer tümörleri aramak ve kontrol altına alabilmek içinde kullanılır. Ancak meme kanseri tanısı konan her birey için MRG' ye ihtiyacı yoktur. Yüksek risk altında bulunan bireylerde mamogram ile beraber kullanılması tavsiye edilir. Bunun sebebi ise mamogramın bulabileceği bazı kanserleri gözden kaçırabilir. Radyologlar ve uzman hekimler aile geçmişi de bakarak MRG taramasının kişi için uygun olup olmadığına karar verebilir. MR' da memenin iyi huylu hastalıklarında da şüpheli bulgular tespit edilebiliyor. Çok erken evredeki meme kanserleri MR ile tespit edilemediğinden her zaman diğer görüntüleme yöntemleri ve klinik muayeneler ile beraber değerlendirilmesi gerekiyor. MR ile yumuşak dokuların görüntülenmesinde daha başarılı sonuçlar alınabiliyor, diğer görüntüleme yöntemlerinde tespit edilemeyen pek çok kanser durumunun tespiti yapılabiliyor. Ancak meme kanserinin tespitinde MR tek başına yeterli değildir.



Şekil 1.3. (a) Normal bir meme MR görüntüsü (b) Bir Tümörün MR görüntüsü (Kuhl, 2000)

1.1.4. Bilgisayarlı Tomografi

Günümüzde meme kanseri teşhisinde erken tanı yaşanan ciddi zorluklardandır. Standart tarama yöntemlerinin her birinin farklı avantaj ve dezavantajları vardır ancak BT taraması şuan da en yaygın olarak kullanılan tarama yöntemidir. Bunun sebepleri ise

kolaylıkla ulaşılabilir olması, maliyetinin uygun olması, taramanın kısa sürmesi ve operatöre bağımlı olmamasıdır (Maspero ve ark., 2020). Meme kanserinin teşhisi için zaman zaman daha hassas, daha erken bir durumda yani metastazlar oluşmadan önce teşhisler yapılabilir. Bu durumlarda BT daha yoğun kullanılmaktadır. BT taramaları; tümörün şeklini, boyutunu, yerini ağrısız bir şekilde ve kısa bir süre de görüntülenmesini sağlar.

BT taraması, vücudunuzun içinin detaylı olarak görselleştirilmesini oluşturmak için röntgen ve bilgisayar ile kullanılan bir testtir (Kaynak belirtilmeli). Vücudu farklı açılardan görselleştirir. Geliştirilen özel bir yazılım ile bu fotoğraflar 3B olarak birleştirilir ve BT görüntüsü ortaya çıkar. Bu kanserin ameliyat ile tedavi edilip edilmeyeceği noktasında tıp uzmanlarına yardımcı olmaktadır.



Şekil 1.4. Deride yaygın kalınlaşma, meme yoğunluğunda asimetri ve yaygın sol aksiller lenfadenopatiji gösteren BT taramasının seçilmiş görüntüsü (Takeda ve ark., 1998)

2. YAPAY ZEKÂ MODELLERİ

Son yıllarda bilgi teknolojileri araçları, şirketlerin pazardaki rekabet güçlerini geliştirmelerini ve giderek daha yenilikçi hale gelmesinde hızlı ve aktif rol almaktadır (Lattie ve ark., 2020). YZ alanı insan zekâsını yeniden kullanmayı amaçlayarak bilgisayar kullanımını gerektiren görevleri yerine getirir. Bu anlamda Makine Öğrenimi şuanda gelişen teknoloji ile daha baskın hale gelmiştir. Basitçe ifade etmek gerekirse; YZ bilgisayarların büyük miktarda veriye dayalı müşteri talebi ve karar verme tahminleri yapmasını sağlar. Makinelerin aldıkları bilgiyi öğrenerek ve bu bilgilerle tahmin yeteneklerini geliştirmeleriyle YZ'nin kullanımı ve potansiyeli artmaktadır.

YZ, lineer modellerin klasik süreçlerinin üstesinden gelmeyi başarmıştır. Örnek vermek gerekirse; finans ve tıp gibi alanlarda değişik sistemler ve uygulamalar kullanılmasına rağmen uyum sağlayan yeteneklere sahip Makine Öğrenimi ve DÖ modellerini içermekte ve başarıyla kullanmaktadır (Brunette ve ark., 2009).

MÖ, verileri işleyerek ve geçmiş deneyimleri alarak otomatik ve eklenebiliyorsa çevresel etkileşim yoluyla öğrenmek için programlama algoritmalarından faydalananak çıktılar üretmeye çalışan bir YZ dalıdır (Yue ve ark., 2018). Makine öğrenimi gerçekten yararlı kılan durum, algoritmanın önceden herhangi bir programlama yapmadan öğrenmesi ve sonuçlarını yeni verilere uyarlayabilmektedir.

MÖ, DÖ ve YZ arasındaki ilişki hakkında birçok bulmaca var. YZ, insan zekâsını simüle eden, genişleten ve genişleten teorileri, yöntemleri, teknikleri ve uygulamaları inceleyen ve geliştiren yeni bir teknolojik bilimdir (Ahmad ve ark., 2013). MÖ, ayrıca insan zekâsının detaylarını anlamaya ve insan zekâsı gibi benzer şekilde yanıtlar vermeye çalışan bir çeşit akıllı makineler meydana getiren bir bilim olarak anılmaktadır. Makine öğrenimi ile alakalı yapılan araştırmalar; robotik, bilgisayarlı görme, Doğal Dil İşleme (DDİ) gibi uzman sistemleri içermektedir. YZ, bir çeşit insan bilincinin bilgi sürecini veya düşünmeyi yani tahmini simüle edebilmektedir. YZ, insan zekâsı gibi değildir ancak programlama algoritmaları ile insan gibi düşünebilir ve insan zekâsını da aşabilecek bir güce sahiptir.

Makine öğrenimi, YZ'nin bir dalıdır ve bilgisayarları kullanarak tahmin yapmaya da odaklanan hesaplama istatistikleriyle yakından ilişkilidir (ve genellikle bunlarla örtüşür). Teori ve uygulama alanları sağlayan matematiksel optimizasyon ile güçlü bağları vardır. Makine öğrenimi bazen veri madenciliği ile birleştirilir (Ebert ve Louridas, 2016) ve daha çok veri analizine odaklanır ve bu da denetimsiz öğrenme

olarak bilinir. Makine öğrenimi ayrıca denetimsiz olabilir ve çeşitli varlıklar için temel davranış profillerini öğrenmek ve oluşturmak için kullanılabilir ve ardından anlamlı anormallikleri bulmak için kullanılabilir (Shia ve ark., 2021). Makine öğreniminin öncüsü Arthur Samuel, MÖ'yü "bilgisayarlara açıkça programlanmadan öğrenme yeteneği veren bir çalışma alanı" olarak tanımlamıştır (Quinto, 2020).

Makine öğrenimi ile ilgili araştırmalarda yeni bir alan olan DÖ, gelişimini analitik düşünme için insan beynini bir sinir ağı yardımıyla simüle etmektedir. Görüntüler veya metinlerin yorumlanmasında insan beyninin mekanizmasını taklit etmektedir (Niu ve ark., 2021).

Veri öğrenmenin yöntemlerine bağlı olarak ortaya çıkan DÖ, bir MÖ yöntemidir. Makine öğreniminin yöntemlerine benzer şekilde, DÖ yöntemlerinde de denetimli öğrenme ve denetimsiz öğrenme vardır. Verileri öğrenme çevreleri çeşitli olduğundan öğrenme modelleri de aynı şekilde çeşitlilik göstermektedir. DÖ'nün faydalarından biri de, özellikleri manuel olarak verimli bir şekilde değiştirmek için denetimsiz veya yarı denetimli özellik öğrenme ve hiyerarşik özellik çıkarmanın kullanılmasıdır (Mandapati ve ark., 2022)

Makine öğreniminde kullanılan tekniklerin çoğu yaklaşık elli yıldır bilinen matematiksel ve istatistiksel teorilere (gelişmiş istatistikler, karar ağaçları, Bayes ağları, sinir ağları vs.) dayanmaktadır. YZ modellemeyi tamamen yeni bir düzeye taşıyarak insan dili ve duygularının anlaşılmasını önemli ölçüde geliştirir. YZ sayesinde finansal süreçlerde yatırımcıların hareketlerini inceleyen ve tahmin eden, hastalıkların tanılarını koymak için rehberlik eden modeller de oluşturabilmektedir. Mevcut verilerden otomatik olarak öğrenmenin birkaç yolu da bulunmaktadır.

Denetimli Öğrenme:

Denetimli öğrenme, yeni kalıplar oluşturmaya yarayan, sınıflandırılması önceden yapılmış bilgi yapısı oluşturur (Sivakumar ve ark., 2018). Denetimli öğrenmenin temel görevi, özelliklerini giriş katmanından alarak sınıf denilen bir çıktıya eşitlemeye çalışır. Bu öğrenmenin sonucuyla girdi modelleri incelenerek bir model oluşturur. Oluşturulan bu model, girilen verilerden doğru bir şekilde sınıflandırmak için kullanılır.

Oluşturulan algoritmalar ile girdileri istenen çıktılara eşleyen bir yapı oluşturulur. Denetimli öğrenme görevinin standart bir formülasyonu sınıflandırma problemidir: öğrencinin, fonksiyonun birkaç girdi-çıkı örneğine bakarak bir vektörü

birkaç sınıftan birine eşleyen bir fonksiyonu öğrenmesi (davranışını tahmin etmesi) gerekir.

Denetimsiz öğrenme: Kısaca sistemlerin nasıl temsil edilebileceğini inceler. Denetimli öğrenmenin tersine, her girdiyle ilgili sonuç üretme ve çevresel değerlendirmeler yapmaz. Bunun yerine denetimsiz öğrenen ve girdinin hangi yönlerinin çıktıda olması gerektiğine dair şüpheler barındırır. Genellikle bilinmeyen bir olasılık altında yatan bağımsız değişkenler olduğu varsayılan gözlemlenebilen girdi kalıpları ve çıktıda önemli olan parametre ne ise ona dair bazı açık ve ön bilgileri içerir (Ferro ve ark., 2021).

Destek öğrenme: Denetimli ve denetimsiz öğrenmenin ortasıdır diyebiliriz. Veri kümesinden kısmen etkilenir. Küçük miktarda eğitim verisi ile test verilerini etkileyebilir. Eğitim verileri olarak bazı kalıplardan etiketli bir model oluşturur ve oluşturulan bu model ile geri kalanını da ele alır (Islam ve ark., 2020).

MÖ ve DÖ arasındaki farkları incelemek gerekirse;

- Veri Bağılıkları, DÖ yöntemi ile makine öğrenimi arasındaki ana farklılık, veri miktarıdır. Veri miktarı arttıkça modelin performansı da artmaktadır. DÖ algoritmaları, veri seti küçük olduğunda iyi performans göstermezler. Bunun sebebi de veri miktarı arttıkça daha fazla test edebilir ve mükemmel sonuçlar çıkarmasıdır. Bunun aksine MÖ, böyle bir durumda daha net kuralları kullanarak performansı daha iyi hale getirmektedir (Niu ve ark., 2021).
- Donanımdaki bağımlılıklar, DÖ yöntemleri çok sayı da matris kullanmaktadır. İşlemci matris çeşitliliğini verimli bir şekilde optimum seviyeye getirmek için kullanılmaktadır. DÖ'nün daha sağlam çalışabilmesi için makinenin işlemcisi çok önemlidir. DÖ algoritmaları yüksek performanslı işlemci kullanırken makine öğrenimi daha düşük performanslı işlemciler ile çalışabilmektedir. Bu durum DÖ yöntemlerinin daha maliyetli olduğunu göstermektedir (Coelho ve ark., 2017)
- Özellik işleme, karmaşık veriler ile ilerlemek daha zor olduğundan karmaşıklığı azaltmak ve öğrenme algoritmalarının daha yüksek performanslı çalışmasını sağlayan yapılar oluşturmaktadır. Oluşturulan bu yapılar alan bilgisini bir özellik oluşturucuya yerleştirmeye çalışır ve bu sürece de özellik işleme süreci denmektedir. Bu yapıyı oluşturmak zaman alabilmektedir. MÖ de, bir uygulamanın özelliklerinin çoğu bir uzman tarafından belirlenmeli ve ardından veri türü olarak kodlanmalıdır. Oluşturulan özellik yapıları; çıktının görselin piksel değerleri, oluşturulan veya alınan şekiller, dokular, konumlar ve yönler gibi bilgilerden olabilir. MÖ'nün

performansı, oluşturulan özelliklerin doğruluğuna bağlıdır. DÖ ve geleneksel MÖ algoritmaları arasındaki temel fark, doğrudan elde edilen yüksek seviyeli özellikler elde etmeye çalışmaktır diyebiliriz (Wang ve ark., 2021). Bu sebeple DÖ, problem için bir özellik çıkarma yapısına duyulan ihtiyacı azaltmaktadır.

- Problem çözme yöntemi, var olan sorunlara çözüm bulmak için oluşturulan DÖ algoritmalarını uygular, MÖ yöntemi ise genellikle sorunu alt sorunlara bölerek alt sorunlardan ana sorunu çözmeye çalışır. Buna göre DÖ uçtan uca problem çözmeyi savunur.
- Uygulama vakti, DÖ algoritmasını eğitmek uzun zaman alabilmektedir çünkü DÖ algoritmasında fazla parametre olabilir. Bundan dolayı, parametrelerin eğitim adımları katkısı fazla olduğundan daha uzun sürer. ResNet gibi en gelişmiş DÖ algoritmasının bir eğitim oturumunu tamamlaması tam olarak iki hafta alırken, MÖ eğitimi nispeten az zaman alır, yalnızca saniyeler ile saatler sürer. Ancak test edilme süresi tam tersi olmaktadır. DÖ algoritmaları test sırasında daha az zaman ile çalışmaktadır. Bazı MÖ algoritmalarında, veri miktarı arttıkça öğrenme süresi de otomatik olarak artmaktadır. Ancak bu tüm makine öğrenimi algoritmaları için geçerli değildir. Veri miktarının yüksek olduğu ancak daha hızlı çalışan modellerde bulunmaktadır.
- Yorumlanabilirlik, MÖ ile DÖ'yü karşılaştırmada önemli bir faktördür. El yazısıyla yazılan sayıların DÖ ile tanıma da, insanların standartlarına yaklaşabilir ve oldukça şaşırtıcı bir performans oluşturmaktadır (Niu ve ark., 2021). DÖ, bir sinir ağının matematiksel olarak bakış açısından etkilenebilir. Bu nedenle, sonucun nasıl üretildiğini açıklamak zordur. Tersine, makine öğrenimi algoritması, algoritmanın neden böyle seçtiğine ilişkin açık kurallar sağlar; bu nedenle, kararın arkasındaki mantığı açıklamak kolaydır.

Makine öğrenimi yöntemi temel olarak dört adımı içermektedir (Ebert ve Louridas, 2016):

- Özellik Mühendisliği. Tahmin için temel olarak seçim (nitelikler, özellikler).
- MÖ algoritmasını seçerken en uygun olanı yakalamaya çalışır. Yüksek karmaşık ve hızlı sonuç alma gibi.
- Oluşturulan modelin performansının eğitilmesi ve modelin performansının değerlendirilmesi (Farklı algoritmalar için en iyi performans gösteren modeli değerlendirin ve seçin.)

- Verileri sınıflandırmaya çalışır veya eğitilmiş verileri kullanarak tahmin etmeye çalışır.

DÖ adımları MÖ adımlarına çok benzemektedir. Hatta çoğu zaman karıştırılmaktadır. Yukarı da maddelerde bahsettiğimiz temel farklar belirtildi. En belirgin fark MÖ'nün otomatik olmadan da sürdürülebilir olmasıdır. Modelleme yaparken DÖ yöntemleri mi, MÖ yöntemleri mi, kullanılmalı. Bunu deneme yanılma ile de doğru sonuca gitmek mümkündür. 3 farklı yöntem olan denetimli öğrenme, denetimsiz öğrenme ve yarı denetimli öğrenme yöntemleri kullanılarak yüksek doğruluk sağlanabilir.

Makine öğrenimi algoritmaları arasında yaygın olarak kullanılan En Yakın Komşuluk (EYK)' tur. Bu algorithmada katman ve düğüm noktası gibi birçok parametreyi seçmek gerekmektedir. Eş zamanlı olarak model ve bu modele uygun seçilen entegrasyon eğitim tamamlandıktan sonra çeşitli bakış açılarıyla değerlendirilerek alternatif modeller oluşturmaktadır. Oluşturulan bu modeller ile uygulanmak istenen probleme karşı çeşitliliği fazla model elde edilir ve bu modellerden en uygun olanı seçilir.

Makine öğreniminin yapısını oluşturan en önemli parçalardan biri de modelin değerlendirilmesidir. Çeşitliliği fazla olan MÖ yöntemleri, farklı değerlendirme modellerine sahiptir aynı zaman da sınıflandırma, kümeleme ve benzeri çeşitlilik gösteren farklı değerlendirme göstergeleri de bulunmaktadır (Gambella ve ark., 2021). Karışıklık matrisi, sınıflandırma sonuçlarının doğru veya yanlış sınıflandırılıp sınıflandırılmadığını ve farklı sınıfların ayırt edilip edilmediğini, ikili sınıflandırma için 2×2 matris ve n sınıflandırma için bir $n \times n$ matrisi için ayrıntılı olarak açıklayan bir tablodur (Luque ve ark., 2019).

2.1. Yapay Zekâ

Modern yapay zeka (YZ) araştırması, 1956 yılında Dartmouth Konferansı ile başlamıştır. Bu konferansta, John McCarthy, Marvin Minsky, Nathaniel Rochester, ve Claude Shannon gibi önemli isimler, "düşünen makineler" konusunu tartışmış ve YZ terimini kullanmışlardır (Rajaraman, 2014).

Çoğu araştırmacı matematiksel teorilerin kanıtlanması ve problemlerin çözülmesi için otonom akıl yürütme yöntemlerini kullanmaya başladı (Talari ve ark., 2019; Robertson ve ark., 2018). Sonra ki süreçlerde uygulamalı YZ merkezi noktaya

alındı. Bu başarılı gelişmeler akıllı sistemleri ve akıllı makinelerin üretilmesi ve gelişmesi inancını destekler niteliktedir. Bu çalışmalar ve gelişim bile hala alınması gereken uzun bir yolun olduğunu göstermekteydi. Sonuç olarak kuruluşlar ve fon sağlayıcılar, yetersiz teslim edilen bu YZ projelerini desteklemeyi engelliyordu (Hamet ve Tremblay, 2017).

1980’lerde birçok üniversitedeki araştırmacıların karar alma noktasında yardımcı katman olarak uzman sistemler ve bir dizi temel kuralı referans alan çalışmalarla bir çeşit YZ sistemini kullanmalarıyla, YZ’nin popülerliğini ciddi oranda arttırdı (Kakileti ve Manjunath, 2020). Oluşturulan uzman sistemlerle tasarlanan XCON ve MYCIN'dir (Peñafiel ve ark., 2018). Bunlar Carnegie Mellon ve Stanford Üniversitesi tarafından geliştirildi. Bu sistemlerle gerçek dünyadaki sorunları çözmek için ilk kez mantık kuralları fikri ortaya atılmıştır. Bu dönemde YZ, makineleri daha akıllı yapan bilgi olarak adlandırılmıştı (Xu ve ark., 2021). Bununla birlikte, uzman sistem, gizlilik teknolojileri, esneklik eksikliği, zayıf çok yönlülük, pahalı bakım maliyeti ve benzeri gibi çeşitli dezavantajları yavaş yavaş ortaya çıkardı. Bu sebeplerden dolayı dünyada, YZ projelerine ayrılan fonlar kesildi ve YZ araştırmaları ciddi anlamda popülerliğini yitirme noktasına geldi.

2006'da Geoffrey Hinton ve çalışma arkadaşları daha derin sinir ağları oluşturmaya yönelik bir yaklaşımın yanı sıra eğitim sırasında gradyan kaybolmasını önlemenin bir yolunu önererek YZ' de bir hamle yaptı (Hinton ve Salakhutdinov, 2006). DÖ özellikle temsil öğrenimi ile birçok sinir ağ katmanı oluşturuldu. Bu sinir ağ katmanlarıyla MÖ yöntemi geliştirildi (Janiesch ve ark., 2021). Bu nedenle, “öğrenmek”, bu YZ araştırması çağının anahtar kelimesidir. Büyük veri teknolojileri ve bilgi işlem gücünün geliştirilmesi, büyük veri örneklerinden özellik ve bilgi türetmeyi daha verimli hale getirdi. DÖ algoritmaları bilgisayarlı görme ve DDİ alanlarında bulunan veri kümelerinde zekâ yeteneklerini geliştirir ve yardımcı olur (Liu ve Lang, 2019). Hayatın her alanında önemli başarılar elde edilen YZ teknolojileri çeşitli bilimsel araştırmalarda ana gövde görevini göstermektedir (Sharma ve ark., 2021).

YZ içinde MÖ, teknoloji ve bilimin birçok alanında önemli bir geniş etkiye sahiptir. Bilgisayar biliminden yer bilimine, malzeme bilimine, yaşam biliminden tıp bilimine, kimyadan matematiğe, fiziğe yönetim biliminden ekonomiye, psikolojiye ve yararlı içgörürler elde etmek kategorize etmek, tahmin etmek ve yeni yollarla kanıta dayalı kararlar almak için yüksek verimli verileri analiz etmek üzere makine öğrenimi yöntemleri geliştirildiği için diğer veri yoğun deneye dayalı bilimlerdir. Aşağıdaki

bölümler, bilimlerin gelişimini teşvik etmek ve uygulamalarını hızlandırmak için YZ tekniklerini geliştiren veya kullanan bilgi bilimi (bilişim), matematik, tıp bilimi, malzeme bilimi, yerbilimi, yaşam bilimi, fizik ve kimya dâhil sekiz temel bilimi inceler. YZ, gerçek dünyada neredeyse her alanda fayda sağlamaktadır.

Güncel araştırmalar ve yapılan uygulamalar gösteriyor ki YZ, alt yapısından faydalanmadan, katma değerli bilimsel çalışmaların yapılması ciddi oranda zorlaşmaktadır. Veri depolama, elde ettiği veriyi işleme gücü YZ'nin çerçevesini oluşturmaktadır. Algı katmanı, makinelerin temel görme, işitme vb. yeteneğe sahip olmasını sağlar. Bilgisayarlı görüntüleme işlemleri makinelerin nesneleri görüntülemesini ve anlamlı veri haline getirilmesini sağlarken, konuşma ve tanıma gibi nesnelerin birbirini tanımasını YZ'ye örnek verebiliriz. Bilişsel katman, DDİ bilgi grafikleri ve sürekli öğrenme yardımıyla tümevarım, akıl yürütme ve bilgi edinme konusunda daha yüksek yetenek seviyeleri sağlar. Temel bilimler, endüstriyel üretim, enerji, sosyal etkileşim ve uzay teknolojisini YZ'nin etki ettiği diğer alanlar olarak karşımıza çıkmaktadır. Aşağıdaki alt bölümler, bilgi alanındaki YZ çerçevesine, otomatik MÖ teknolojisine ve son teknoloji YZ/MÖ uygulamalarına genel bir bakış sağlar (Das ve ark., 2015).

Son yıllarda YZ'ye dayalı uygulamalar, çeşitli alanlarda ve konularda önemli roller almıştır (Nichols ve ark., 2019). Temelinde DÖ ve MÖ çerçevesinde ve platformların zenginlikleri üzerine kurulmuştur. YZ çerçeveleri ve platformları, farklı alanlardan araştırmacıların diğer alanlarda kullanmalarını sağlayan genel algoritma geliştirme süreçlerini entegre ederek, YZ teknolojisine erişim gereksinimini azaltıp, sinir ağlarının yapısını tasarlamaya odaklanmalarını sağlamıştır. Böylece daha birçok konuda çok daha iyi çözümler sunar. YZ'nin yükselmeye başladığı dönemlerde OpenNN ve Torch gibi sistemler sinir ağlarını tanımlamakta ve gelişimine katkı sunmaktaydı (Parvat ve ark., 2017). Bu dönemde bu çerçeveleri kullanmak, profesyonel bilgisayar bilimi bilgisi ve model inşası üzerinde sıkıcı bir çalışma gerektiriyordu. Çözüm olarak, ESA, Tekrarlayan Sinir Ağları (TSA) ve Uzun Kısa Süreli Bellek (UKSB), YZ modellerinin uygulama maliyetini önemli ölçüde azalttı. Ardından teknoloji devleri, YZ çerçevelerini araştırma yürüyüşüne katıldı (Canhoto ve ark., 2020). Google, açık kaynak kodlu olan TensorFlow'u geliştirdiği dönemlerde Facebook'un YZ araştırma ekibi ise Torch alt yapısını kullanan PyTorch'u piyasaya sürmeye başladı (Liermann, 2021). Microsoft araştırma ekibi CNTK'yi yayınladığı dönemlerde Amazon ise MXNet'i duyurmaya başladı. Bu dünyaca ünlü firmaların aynı

zamanda en geniş çerçeveli olanı, Google' un geliştirdiği TensorFlow grafik tabanlı optimizasyon için geniş alanda katkı sunmaktaydı. Facebook'un geliştirdiği PyTorch ise daha çok kullanıcı dostu olarak, sezgisel çalışmalar üzerine yoğunlaştı. 10 Süper ölçekli model eğitimi yeteneği ileriye dönük olarak, bazı eğilimleri bulunmaktadır ve oluşturulan yeni nesil çerçeve geliştirmenin ana akımı haline gelebilir. Yüzlerce, hatta binlerce cihaz ölçeğinde etkili bir şekilde eğitmek için YZ çerçeveleri gerektirir. Bu çerçevelerin API'leri birbirine benzemektedir. Ancak bu benzeme bazı alanlarda farklılık göstermektedir. Bu durum kullanıcısı olan sistemlerde bir dezavantaj haline gelmektedir. Bu durum bazı zorluklara ve gereksiz verilerin eğitilmesine, sistemin bu verileri öğrenmesine sebep olmaktadır. Bazı çerçevelerin API'leri JAX gibi uygulama geliştiricilerin standartları ile anlamlı hale gelmeye başladı. DÖ teknolojisi iyi sonuçlar aldığından çok hızlı gelişim göstermektedir. Bu durumda genellikle yeni algoritmaların destek aralığının ötesinde gelişim göstermesine neden olmaktadır (Shrestha ve Mahmood, 2018).

YZ algoritmalarını otomatik olarak oluşturmak için evrimsel bilgilerin işlenmesi, pekiştirmeli öğrenme ve diğer YZ algoritmaları, MÖ'nün YZ algoritmalarında nasıl kullanılacağını gösterir. Yapay Sinir Ağları'nın (YSA) otomatik üretimi üzerine araştırmalar, örneğin sinirsel evrim gibi, DÖ'nün ortaya çıkmasından önce de vardı (Szolovits ve ark., 1988). Bir popülasyondaki verilerin seçimi, bireysel kalitesi sürekli olarak geliştirilir ve en büyük uygunluğa sahip olduğunda en iyi şekilde sinir ağını temsil eder. İnsan beyni çok gelişmiş nöronlara sahip olduğundan beyindeki karmaşık sinir ağı sistemi olmazsa olmazdır. DÖ dönemlerinde otomatik DSA oluşturmak için, YZ algoritmalarının uygulanması daha fazla belirgin olmaya başladı ve aynı zamanda MÖ araştırmalarının önemli bir kısmına dönüşmeye başladı. PÖ tabanlı yöntemde, bir sinir ağı yapısını katman oluşturmak için bir kontrolör olarak bir TSA kullanılır ve ardından ağ eğitilir ve doğrulama kümesinin doğruluğu, TSA'nın hesaplamak için ödül sinyali olarak strateji gradyanı kullanılır. Yineleme sırasında, denetleyici, strateji işlevinin uygun ağ yapısını çıktı olarak verebilmesini sağlamak için sinir ağına daha yüksek doğrulukla, daha yüksek bir olasılık değeri verecektir (Kaur ve ark., 2019). Sinir mimarisi arama yöntemi, sinir ağı ile benzerlik göstermektedir. Yüksek kaliteli bir sinir ağı elde etmek için bir popülasyona dayanan ve en uygun olanın hayatta kalması ilkesine göre sürekli olarak yinelenen evrim yöntemi (E. Real). Sinir ağlarının tasarımı daha verimli ve otomatiktir. Bunun sebebi sinir sistemi mimarisi arama teknolojilerinin kullanılmasıdır. Örneğin, Google'ın SOTA ağı EfficientNet, sinir


mimarisi aramasına dayalı temel ağ üzerinden gerçekleştirildi (Xu ve ark., 2021; Benmeziane ve ark., 2021).

YZ'nin diğer alanlarda kullanımları:

- Kamu hizmetlerinde YZ tabanlı risk kontrolü ve yönetimi, zamanında bakım veya otomatik kapatma sağlamak için oluşabilecek olası sorunları tahmin ederek, makinenin sağlığıyla ilgili bilgileri algılayan ve üreticiye gönderen sensörler kullanarak maliyetli veya tehlikeli takım arızalarını önleyebilir.
- Gerçek dünyadaki nesnelerin simülasyonlarını oluşturulması için kullanılır. Tıp ve mühendislik alanlarında uygulandığında teknik personellerin sistem performanslarını sanal ortamda analiz etmeleri için ciddi olanak sağlamaktadır.
- Akıllı robotların ve insan yaşamında ve endüstriyel sistemlerde kullanılmasıyla, YZ'nin insan hayatındaki rolü de önemli ölçüde artmaktadır. Sistemler için insanlar tarafından oluşturulan prosedürler ile çalışan akıllı robotlar farklı çevrelere göre değişkenlik gösterdiğinden; algılama, tanıma ve hatta otonom olarak planlama ve karar verme yeteneklerine sahip olmaktadır.
- Nesnelerin YZ'si veya YZ destekli Nesnelerin İnterneti (Nİ) uygulamaları insan hayatı için gelişime açık olduğundan bir eğilim haline geldi (Yang ve ark., 2020). YZ, çeşitli fiziksel altyapılara gömülü olan bağlı Nİ cihazlarını algılamak, tanımak, öğrenmek ve harekete geçmek için güçlendirebilir. Örneğin, akıllı şehirler, şehirlerdeki sistemleri yönetmek ve optimize etmek için güç kaynağı, toplu taşıma, hava kirliliği ve su kullanımı gibi yaşam kalitesi faktörleri hakkında sürekli olarak veri toplar. Bu veriler nedeniyle özellikle bilgili veya bilgisiz katılımcılardan toplanan kişisel veriler, veri güvenliği ve mahremiyeti (Wu ve ark., 2018) koruma gerektirmektedir.

İnsan zekâsının tarihi; asırlar boyunca insan akıl yürütmesini mantıksal bir çerçeveye indirgeme girişimlerinden sembolik YZ'nin en olağan ve kaçınılmaz mümkün olmayan karmaşık hesaplarını basitleştirmeye uğraşmıştır. YZ, görevlerin belirli bir zekâ ile yapılması veya karar verilmesi için özel yazılım ve programlar geliştiren bir tür bilgisayar bilimi olarak tanımlanır. Bu özel yazılımlar ile verilen elde edilmesi ve anlamlı hale getirilmesi arasındaki açığı kapatmamıza yardımcı olur. Gelişen özellikleri ve teknoloji ile birlikte yaşamımızın tüm neredeyse tüm alanlarında ana akım haline gelmeye başlamıştır (Nasim ve ark., 2022). Geçmişten günümüze gelen Alan Turing ve John von Neuman ile 1950'lerde başlamıştı (Istrail ve ark., 2012).

Medikal alanda ve özellikle onkolojinin çeşitli kısımlarında; Tümör tespiti, tanısı, gelişiminin izlenmesi, klinik karar vermenin yanı sıra kanser tedavisinin geliştirilmesi, hastalığın doğrulanması ve tahmini noktasında önemli rol almaktadır. Şekil 2.1’de Yapay zekânın bilgi akış süreci özetlenmektedir.



Şekil 2.1. Yapay zekâ ve bilgi işleyişi

Veri tabanından alınan bilgiler bilgisayarlar tarafından derlenerek öğrenilerek sonuç almayı sağlamaktadır. Bilgisayarların öğrenmesi, öğretilen algoritmalar sayesinde gerçekleşir. Çıkarılan sonuç ise bilgisayarın öğrenmesiyle elde edilen bir çıktıdır.

2.1.1 Matematikte Yapay Zekâ

Matematik, YZ'de her zaman çok önemli ve vazgeçilmez bir rol oynar. Onlarca yıl önce, EYK, Destek Vektör Makineleri (DVM) ve AdaBoost gibi oldukça az sayıda klasik YZ ile ilgili yaklaşım, titiz matematiksel formülasyonları oluşturulduktan sonra önerildi ve geliştirildi (Shravya ve ark., 2019). DÖ'nün insan hayatında daha fazla yer almasıyla beraber son dönemlerde YZ, matematik bilimi alanında daha fazla yer almaya başladı. Markov süreci, minimaks optimizasyonu ve Bayes istatistikleri ile donatılan PÖ, GANs ve Bayesian öğrenme, birçok YZ sistemlerinde kullanıma uygun hale geldi (Papamarkou ve ark., 2022). Bu ortama rağmen, ML matematikte sinir ağları yapısının adlandırılması, parametrelerin tahmininin optimizasyonu ve genel olarak verinin

öğrenme yeteneği de dâhil olmak üzere birçok alanda çözülmemiş problemler bulunmaktadır.

2.1.2 Tıp Biliminde Yapay Zekâ

YZ teknolojisinin, tıp alanları da dâhil olmak üzere günlük operasyonlarda giderek daha önemli hale gelmesi yönünde büyük bir eğilim var (Park ve Han, 2018). Hastalar için artan sağlık hizmeti ihtiyaçları ile hastane ihtiyaçları, bilgi açısından İnternet Hastanesine ve günümüzde Akıllı Hastaneye dönüşüyor. YZ sistemlerinin kullanılması ve donanımsal alanda performansların iyileştirilmesi de her geçen gün artış göstermektedir. Bu artışla DDİ ve veri madenciliği gibi geniş YZ algoritmaları tıbbi sistem pazarına dâhil olmaya başlamıştır.

Tıp geçmişi verileri için IBM'in Watson platformu tarafından geliştirilen Doctor Watson'dan ve onkolojiyi çözmeyi amaçlayan Modernizing Medicine'den ABD'de CVS & Walgreens ve Çin'de de çeşitli tıbbi kuruluşlar tarafından benimsenmesi kaçınılmazdır (Allain, 2012). Bilgilerin güncellenmesi bile hala manuel ilerlediğinden çalışmalara ihtiyaç duyulan bilgi bankalarının güncellenmesine önemli ölçüde bağlılık göstermektedir. Bu sebeple bu tür YZ sistemleri birçok bölge için henüz uygun olmamaktadır.

Tıbbi görüntüler, sınıflandırma ve algılama gibi görevleri bulunduğundan, YZ nin en gelişmiş alanlarından biridir (Pesapane ve ark., 2018). Klinik alan için CV algoritmaları ayrıca Elektrokardiyografi (EKG), BT, göz fundus görüntüleme vb. ile BDTS, teşhis ve tedavi için kullanılabilir. Hekimler hastalığın teşhisi için dalgınlık, yorgunluk vs. gibi insani sebeplerden dolayı hataya yapmaya meyilli olduğundan bu YZ sistemleri ile geliştirilen teşhis ve tekrarlanan çalışmalarda uzmanlıkları nedeniyle bir insanın baktığından daha iyi performans gösterebilir. İlk onaylanan tıbbi YZ ürününü gıda ve ilaç idaresi onaylamıştır. Bu ürün diyabetik tahminleri tahmin edebilmek için kullanılan IDx-DR'dir. Akıllı cihazlarda anormal büyüme hareketlerini tespit etmek için fraktal analizi kullanır. YZ ile çekilen EKG görüntüleriyle kalp hastalığı gibi birçok hastalık tespit edilebilmektedir. Hassas tedavileri yüksek çözünürlüklü görüntü teknolojileriyle başarılı bir şekilde gerçekleştirmek mümkündür. Genel olarak bu görüntüleri üretmek için ışın tedavisi ekipmanlarından yararlanılır.

Giyilebilir teknolojinin gelişim döneminde felç ve kalp yetmezliği gibi kritik hastalıklar için erken uyarı mekanizmaları geliştirildi (Kakria ve ark., 2015). Bu

cihazlarla hastalığın daha erken tahminini sağlayan bir algoritma ortaya konuldu. Bu dönemlerde bazı şirketler tükürüklerin kime ait olduğunu ve bu tükürük örneklerini daha küçük maliyetlerle tükürük sahibinin atalarının kim olduğu ve daha sonra ki süreçlerde ne gibi hastalıklara yatkın olabilecekleri gibi olası hastalıklar da dâhil olmak üzere genlerine dayalı çok önemli veriler bulundurmaktadır. Kişiye ve aile genlerine dayalı önemli sağlık çözümleri sunmaktadır. Günümüzde tıp doktorları çoğu zaman YZ modelleri ile kararlar almaya başlamışlardır. Sıradan açıklama yerine YZ modelleri ile kararların açıklanması daha somut verilere dayandırılmaktadır. Bu somut veriler ışığında hastalık üzerinde yeni temel gerçeklerinde keşfedilmesi sağlanabilmektedir. YZ araştırmaları için giyilebilir cihazlar önemli bir alan oluşturmaktadır. Çok farklı verileri toplamak için çeşitli cihazlar ve tüm bu verileri birleştirecek merkezi bir işlemci ile model, kullanıcının genel gerçek zamanlı sağlık durumunu izleyebilir ve daha kesin önlemler verebilir. Teşhisi daha zor olan hastalıkların otomatik keşfi günümüz dünyasında çok önemli sorun olarak karşımıza gelmektedir. Örnek verecek olursak Amyotrofik Lateral Skleroz (ALS) gibi hastalıkların klinik doktorlar tarafından tespit edilmesi şuan hala zor bir süreçtir. Bunun sebebi de genel geçer belirtilerinin olmamasıdır. YZ bu hastalıkları için ortak bir kural seti ile keşfetmek ve erken teşhis için bir sonuç üretmek mümkün olabilmektedir. Sağlık alanında artık çok hassas bir sürece girmiş bulunmaktayız. Bu hassasiyetle beraber ilaçlar teşhisi yapılan hastalığın tedavisinin temelinde bulunmaktadır. Bu ilaçların laboratuvar ortamında geliştirilmesi piyasaya sunulması uzun zamanlar alabilmektedir. Nitekim Covid-19 hastalığında aşının bulunması sürecini tüm dünya olarak oldukça yakından izlemekteydik. İlaçların üretilmesi için gerekli keşif süreçlerinin hızlandırılması veya nasıl hızlandırılacağı ve başarısızlıklardan nasıl kaçınılması gerektiği gibi tüm büyük ve rekabetçi ilaç firmalarının temel endişelerini oluşturmaktadır. MÖ, DÖ ile geliştirilen uzman sistemler ve YSA'lar da dâhil olmak üzere YZ' nin anlatılmaya çalışılan ve gelişim gösteren rolü yeni ilaçların keşif süreçlerinde yüksek verimlilik göstermektedir.

YZ'de novo molekül tasarımı, proteinler ve ligandlar için yapı temelli modelleme, nicel yapı-aktivite ilişkisi araştırması ve ilaçlanabilir özellik yargıları dâhil olmak üzere ilaç keşfinin birçok alanında benimsenmiştir. DÖ tabanlı YZ cihazları, ilaç keşfindeki bazı zorlu problemlerin ele alınmasında üstün değerler gösterir. Bu durum kimyasal sentez durumlarının tahmini ve kimyasal süreçlerin optimize edilmesi ve yeni ilaç keşif süreçlerinin hızlandırılmasının yanında maliyetlerin düşürülmesi de YZ'nin kullanım amaçlarından biri olmalıdır.

Son yıllarda hem yeni kimyasal varlık keşfi hem de ilgili iş alanı için YZ destekli yeni ilaç keşfinde kayda değer ilerleme kaydedilmiştir (Paul ve ark., 2021). Ocak 2020'de DSP-1181, faz I klinik denemelerine başladı; bu, programın başlatılmasından faz I çalışmasına kadar kapsamlı keşfin 12 aydan az sürdüğü anlamına geliyor. Buna karşılık, geleneksel yöntemlerle karşılaştırılabilir ilaç keşfi, geleneksel yöntemlerle genellikle 4-5 yıl gerektirir.

Kadınlarda en sık görülen kötü huylu tümör olan rahim ağzı kanseri, nedeni açık olan ve erken teşhis edildiğinde önlenebilen hatta tedavi edilebilen bir hastalıktır (Beharee ve ark., 2019). Servikal kanser için tarama aşaması esas olarak servikal sitoloji-kolposkopi-histopatoloji olmak üzere üç aşamalı modeli benimsenir. Ancak, test yöntemlerinin düzeyi ile sınırlı olduğundan, servis kanseri taramasının etkinliği yüksek değildir (Xu ve ark., 2021). Ayrıca bazı temel hastanelerde doktorların bilgi eksikliğinden dolayı hastalara en doğru teşhis ve tedavi kararları verilememektedir. Son yıllarda, bilgisayar bilimi ve büyük veri çağının ortaya çıkmasıyla birlikte, YZ yavaş yavaş genişlemeye ve çeşitli alanlara karışmaya başladı. Özellikle YZ, veri madenciliği için yeni bir araç olarak çeşitli kanserlerde yaygın olarak kullanılmaktadır. Rahim ağzı kanseri için milyonlarca tıbbi kayıt ve patolojik veri içeren bir klinik veri tabanı oluşturulmuş ve bir YZ tıbbi araç seti geliştirilmiştir (Li ve ark., 2021). Böyle bir YZ analiz algoritması, doktorların hızlı yinelemeli YZ modeli eğitimine erişmesini destekler (Xu ve ark., 2021). Bu duruma ekleme yapacak olursak, MÖ ile oluşturulmuş bir prognostik tahmin modeli ve kanser hastalarında postoperatif nüks ve ölüm riskini doğru şekilde tahmin edebilmektedir. Böylelikle postoperatif adjuvan tedavide karar vermeye daha iyi referans olan web tabanlı bir prognostik çıktı hesaplayıcı geliştirilmiştir (Guo ve ark., 2021).

2.1.3 Yaşam Bilimlerinde Yapay Zekâ

YZ ve yaşam bilimlerindeki gelişmeler iç içedir. YZ'nin nihai amacı, insan beyni çoklu görev, minimum denetimle öğrenme ve öğrenilen becerileri genelleştirme yeteneğine sahip olduğundan, tümü yüksek verimlilik ve düşük enerji maliyeti ile başarılı olduğundan, insan benzeri zekâ elde etmektir (Leite ve ark., 2021).

Modern bilimin ölçeği, bir nötronun boyutundan Evrenin boyutuna kadar değişir. Ölçeğe göre fizik dört kategoriye ayrılabilir: nötron ölçeğinde parçacık fiziği, atom ölçeğinde nükleer fizik, molekül ölçeğinde yoğun madde fiziği ve evren ölçeğinde

kozmetik fizik (Xu ve ark., 2021).

Gelişen dünya biliminin referans noktası, küçücük bir nötronun boyutundan evrenin boyutuna kadar değişim göstermektedir. Referans noktasına göre fizik;

- Nötron ölçeğinde parçacık fiziği
- Atom ölçeğinde nükleer fizik
- Molekül ölçeğinde yoğun madde fiziği
- Evren ölçeğinde kozmik fizik

4 ana kategoriye ayrılmaktadır. MÖ olarak da adlandırılan YZ, görüntülerin yeniden yapılandırılması ve analizi gibi veri analizlerinde YZ algoritmasının kullanılması ana eğilim olduğundan, farklı ölçeklerde tüm fizikte önemli bir rol oynamaktadır.

2.2. Makine Öğrenme Yöntemleri

Makine öğrenimi, bilgi teknolojisi, istatistik, olasılık, YZ, psikoloji ve diğer birçok disiplinde sunulan geniş bir alanı temsil eder (Aggarwal ve ark., 2022). MÖ ile çözüm aranan problemler, seçilen veri kümesinin ilgili sorunun temsilini iyi bir şekilde yapması gerekmektedir. MÖ genel geçer kurallardan ayrılmış daha ileri bir alan haline gelmeye başladı ve istatistik alanını da öğrenme süreçlerine dâhil ederek istatistiksel hesaplama teorilerini de içine alarak daha geniş bir alan olmaya başladı.

MÖ verileri alarak bilgisayarın öğrenmesini sağlayan algoritmaları oluşturur. Bilgisayarın bu verileri öğrenmesi, istatistiksel prosedürleri ve diğer veri kalıplarını bulmaya çalışır (Çalışkan, 2023a). MÖ algoritmaları (Asri ve ark., 2016; Sharma ve ark., 2018), insanı temsil edebilmek için oluşturulmuştur. Bu algoritmalar aynı zamanda farklı ortamlarda öğrenmenin zorluğuna dair bir öğrenmeyi de gösterebilir.

Büyük veri alanında yeni bilgilerin ortaya çıkması ve gelişimiyle son dönemlerde MÖ önemi de büyük oranda artmaya başlamıştır. Günümüzde birçok MÖ algoritması geliştirildi. Çeşitli karmaşık matematiksel, istatistiksel hesaplamaları otomatik olarak uygulama olanağı MÖ ile daha hızlı alınmaya başladı.

Çok popüler makine öğrenimiyle uygulanabilir hale getirilebilir. Geliştirilen uygulamaların oluşturulan kalıpların tanınması, verilerin öğrenme ve verilerden yeni bilgiler elde etme soyutlama veya verilerin işleme ve verimliliğini optimize etme yeteneğine sahip olduğu makine öğreniminde kullanılır. Buna paralel olarak geliştirilen çeşitli uygulama alanlarında bulunan çok boyutlu verilerle çalışmak için MÖ teknikleri kullanılmaktadır (Shravya ve ark., 2019).

MÖ, deneyimlerden öğrenen ve hesaplama sistemleri geliştiren bunları, üst düzey algoritmalar kullanarak gerçekleştiren YZ'nin alt dalıdır. MÖ, denetimli ve denetimsiz olmak üzere işlemler gerçekleştirmektedir. Denetimli MÖ sisteminde, girdilerin tamamı etiketlidir ve etiketli veriler ilgili algoritmalar tarafından işlenerek sınıflandırma, regresyon gibi işlemleri gerçekleştirir. Denetimsiz MÖ ise veri kümesinde etiket kullanılmadan gruplaştırılması ve kümeleştirilmesi istenir (Çalışkan ve ark., 2022b; Olier ve ark., 2021). MÖ'deki özellikler, doğrudan kaynak verilerden alınabilir. Ancak çoğu zaman ham girdi verilerini modelleme olarak kullanmak daha uygun formata dönüştürmek için kullanılır. Doğal olarak gelen ham verideki dönüşümü öğreten uygulanacak çalışma için daha yüksek doğrusal oran yakalamaya yardımcı olur. Veri dönüşümü için öğrenmeyi bir denkleme dayanmadan verilerden doğrudan öğrenmek için hesaplama yöntemlerini kullanır. Öğrenme için mevcut veri örnek sayısı arttıkça algoritmanın performansını arttırmak için daha adapte olur.

2.2.1. Destek Vektör Makineleri

Bu çalışma için DVM, EYK ve Lineer Diskriminant Analizi (LDA) yöntemleri kullanıldı. Yöntemleri temel olarak anlatmak gerekirse; DVM, sınıflandırma ve regresyon sorunlarında uygulanan ve genellikle denetimli öğrenme yöntemlerinde kullanılan bir yöntem kümesidir (Wang ve ark., 2018). DVM sınıflandırıcısının on yıl önce tanıtılmasından bu yana, DVM sağlam teorik temeli nedeniyle popülerlik kazandı (Ozer ve ark., 2020). Katma değerli uygulamaların gelişmesiyle beraber yeni uygulamalarında ardından gelmesine neden olmuştur (Huang ve ark., 2018).

DVM'nin temel amacı, N boyutlu uzaysal bir düzlemde veri noktalarını belirgin bir şekilde sınıflandırmaktır. Farklı noktalarda bulunan iki veri noktasını sınıflandırıp ayıran ve seçebilme özelliğine sahip birçok olasılıklı hiperdüzlem bulunmaktadır. Burada amacımız, iki ayrı sınıf noktasını ayırmak için gerekli en uzun mesafeye sahip düzlemi bulmaktır. Mesafeyi arttırmak ve en uzun mesafe de bu düzlemleri ayırmak problem ile ilgili ileride karşılaşılabilecek sorunlarında önüne geçmek ve daha güvenli bir şekilde sınıflandırma için destek sağlar.

İstatistiksel öğrenme, Vapnik tarafından geliştirilmiştir (Vapnik, 1999). İstatistiksel öğrenme, bir dizi eğitim setleri ile bir fonksiyonu tahmin etmek demektir. Bu istatistiksel öğrenme yapısını kurmak için bir MÖ, bir işlevi seçmektedir ve bu tahmin yani henüz gerçekliği netleşmeyen bir işlev olduğundan riski daha aza

indirmektedir. Riskin karmaşıklığı ve yüksekliği öğrenme sırasında yapı için seçilen fonksiyonun karmaşıklığına da bağlıdır. Bu nedenle en iyi fonksiyonu seçmek riskin en aza indirgenmesi için önemlidir.

Şimdilik, eğitim kümesinin bir hiper düzlem ile ayrılabilir olduğunu varsayalım. Hiperdüzlemler sınıfı için hiperdüzlemin karmaşıklığının başka bir nicelik, marj ile sınırlandırılabilceği kanıtlanmıştır (Vapnik, 1999). Marj en kısa mesafe olarak tanımlanır. Bu sebepten ötürü, bir fonksiyon sınıfının marjını en kısa mesafelerde ararsak yapının karmaşıklığını daha rahat kontrol edebiliriz. DVM marjını en yüksekten hesaplandığında riskin en aza indirilmesi ön görüşünü kullanır. Çok boyutlu uzayda basit bir sınıflandırma yöntemi örnek olarak düşünülebilir. Özellik uzayında ayrılmış iki örnek sınıf ile hiperdüzlem sınıfların ortalamaları arasında olmalıdır. Ortalaması kendisine yakın olan sınıfa yeni bir nokta alan nokta karar yüzeyidir. Karar yüzeyi ayrıca iki vektör arasındaki geometrik hesaplamayı da yaparak bir çekirdek işlemi arasındaki benzerlik açısından örtük olarak tanımlanabilir.

İstatistik öğrenmeye dayalı olarak geliştirilen yeni bir MÖ yöntemi olan DVM, Vapnik tarafından geliştirilmiştir. Yapısal risk minimizasyonu ilkesine dayalı olarak, DVM, karar verme kurallarını alabilir ve bağımsız testler seti için küçük hatalar elde edebilir ve böylece öğrenme problemlerini verimli bir şekilde çözebilir (Huang ve ark., 2017). DVM doğrusal olmayan ve yüksek boyutlu problemlerde de kullanılmaya başlanmıştır. Çoğu pratik uygulamalarda, hesaplama yaklaşımlarına kıyasla daha yüksek boyutlu ve uzun tahmin gerektiren süreçlerde daha yüksek doğruluk sağlayabildiği görülmüştür.

DVM'nin üç ana avantajı vardır bunlar;

- Seçilecek yalnızca iki parametre, üst sınır ve çekirdek parametresi,
- Doğrusal olarak sınırlandırılmış ikinci dereceden bir denklemi çözmek için benzersiz, optimal ve global sorunu, çözümü,
- Genelleme yapabilen sinir ağlarında daha başarılı sonuçlar vermesi beklenmektedir.

Bu avantajlardan dolayı, araştırmacılar tarafından DVM teorisi ve uygulaması ile ilgili çok sayıda çalışma yapılmıştır (Sewak ve ark., 2007; Liu ve ark., 2003; Alfian ve ark., 2022).

Yüzey pürüzlülüğü, kesme kuvveti ve takım ömrü gibi işleme performanslarının tahmini, işlemede zorlu kısım olduğundan, geleneksel işleme operasyonları için işlemin

uygun bir şekilde optimize edilmesini gerektirir. Bunun yerine, işleme sürecinin ekonomisini optimize etmek için kesme hızı, ilerleme hızı ve kesme derinliği gibi kesme koşullarının seçilmesi gerektiği kabul edilmiştir (Ozer ve ark., 2020). DVM'nin en yoğun kullanıldığı süreç; yüzey pürüzlüğü optimizasyonu ve takım aşınmalarının modellemelerinin tahminleridir.

Diferansiyel tahmin farklı popülasyondan uyaran alt sınıflara gönderilen çalışmalar tarafından kontrol edilir. Daha sonra alt gruptan diğer gruplara göre önemli ölçüde daha iyi tahmin performansı gösteren sınıflandırıcı üretirek ve basitçe tanımlayarak farklı reaksiyonlar hakkında fikir edinmektedir. Örnek verecek olursak;

- Çeşitli noktalardan gelen öğrencilerin akademik performanslarındaki sosyoloji ve psikolojideki çok önemli gelişmeler farklılıkları açıklayan sistemleri incelemek için en uygun regresyon kullanıldı (Kadam ve ark., 2019).
- Model yükseltme pazarlama çalışmalarında satış artırıcı popüler bir yöntemdir. Bir kampanyanın etkisini arttırmak için hedeflenen bir alt grup tarafından bir kontrol alt grubu ile yapılan satışları inceleyerek karşılaştırır (Abdullah ve Abdulazeez, 2021).
- Tıbbi araştırmalar genellikle bir ilacın etkisini, ilacı alan hastaları almayan hastalarla karşılaştırarak değerlendirir (Oru ve ark., 2012).
- Meme kanserine yakalanma yaşları, yaş almış kadınlarda daha yavaş ilerlemektedir. Bu nedenle, daha yaşlı ve daha genç hastalar arasındaki farkların anlaşılması, tedavinin hemen gerekli olup olmadığının belirlenmesinde çok önemlidir (Vijayarajeswari ve ark., 2019).

DVM, bir sınıflandırıcı oluşturmak için güçlü bir yöntemdir. Kısaca, bir çekirdek işlevi, aksi takdirde yüksek boyutlu uzayda hesaplamalara ihtiyaç duyacak olan belirli hesaplamaların daha hızlı yapılmasına yardımcı olabilir.

Çeşitli faktörler arasında ana işlevin seçimi bir DVM modelinin performansını etkilemektedir. Ama en iyi yolu seçme yoktur, en iyi çekirdeği bulmanın en iyi yolu denemektir. Basit bir DVM ile başlayıp daha sonra uygun çekirdek işlevleriyle deneme yanılma yöntemiyle bulunabilir.

DVM'ler, parametrik olmayan uygulamalı istatistikler, sinir ağları ve makine öğrenimi ile ilgili ve bunların unsurlarını içeren ikili sınıflandırma görevleri için uygun


yeni bir tekniktir. Klasik teknikler gibi, DVM'ler de bir şirketi, seçilen finansal oranların bir fonksiyonu olan skor değerine göre ödeme yapan veya aciz olarak sınıflandırır.

Sınıflandırma teknikleri analiz edilen verilere göre önem sırasına göre ve göreceli olarak avantaj ve dezavantajları bulunmaktadır. DVM'ler, örneğin veriler düzenli olarak dağıtılmadığında veya bilinmeyen bir dağılıma sahip olduğunda, verilerde düzensizlik olması durumunda iflas analizi için yararlı bir araç olabilir. Genel sınıflandırma yöntemleri modellerinin sonucuna gitmeden önce dönüştürülmesi gereken verilerin değerlendirilmesine yardımcı olabilir. DVM yönteminin avantaj ve dezavantajlarından bahsedecek olursak;

- Çekirdeği tanıtarak, DVM'ler, doğrusal olması gerekmeyen ve hatta işlevi parametrik olmadığı için tüm veriler için aynı işlevsel forma sahip olmayan, çözücüyle iflas eden şirketlerden ayıran eşik biçiminin seçiminde esneklik kazanır ve yerel olarak çalışır. Sonuç olarak, puanla ve temerrüt olasılığıyla monoton olmayan bir ilişki gösteren veya lineer olmayan bir ilişki gösteren finansal oranlarla ve bu monoton olmayan her değişken üzerinde herhangi bir özel çalışmaya ihtiyaç duymadan çalışabilirler.
- Tanıtılan bu çekirdek dolaylı yollarla doğrusal olmayan bir dönüşüm içermektedir. Bu dönüşüm sağlam temellere dayalı bir teorik temel üzerine kurulur ve geliştirilir.
- C ve r parametreleri (Gauss çekirdeği durumunda) uygun şekilde seçilirse, DVM'ler iyi bir örnek dışı genelleme sağlar. Bu, uygun bir genelleme derecesi seçerek, eğitim örneğinde bir miktar önyargı olsa bile DVM'lerin sağlam olabileceği anlamına gelir.
- Optimallik sorunu dışbükey olduğu için DVM'ler benzersiz bir çözüm sunar. Bu, yerel minimumlarla ilişkili çoklu çözümlere sahip Sinir Ağlarına kıyasla bir avantajdır ve bu nedenle farklı örnekler üzerinde sağlam olmayabilir.
- Gauss çekirdeği gibi uygun bir çekirdeğin seçilmesiyle, şirketler arasındaki benzerlik daha fazla vurgulanabilir, çünkü iki şirketin mali yapısı ne kadar benzerse, çekirdeğin değeri de o kadar yüksek olur. Böylece yeni bir şirket sınıflandırılırken, finansal oranlarının değerleri, eğitim örneğinin bu yeni şirkete daha çok benzeyen destek vektörlerinden olanlarla karşılaştırılır. Daha sonra en fazla benzerliğe sahip grupla benzerlik durumuna göre sınıflandırması yapılır.

DVM, popüler bir MÖ yaklaşımıdır. Doğrusal ve doğrusal olmayan sorunların çözümünde kullanılır ve pratiklik isteyen birçok algorithmada iyi sonuçlar sağlar. Bu algoritmalarda girdi verileri işlenir ve burada koordinat düzlemine yerleştirilen hiper çizgiler ile tür sınıflandırması yapılır. En yüksek marh alanı (w) optimize edilerek belirlenir. DVM yönteminin sınıflandırması işlemlerini gösteren açıklama Şekil 2.2’de verilmiştir.

Temel olarak DVM in yaptığı iş; bir hiper düzlem bulur ve bu düzlemi iki parçaya bölen bir çizgi çeker ve her sınıfta her iki tarafta da bulunur. En önemli ölçüt kara limitinin belirlenmesidir. Bu kara limitinin belirlenmesinde denklemler kullanılır. Denklem 1’deki matematiksel formül sayesinde, sınıflandırma işlemi sürecinde oluşabilecek problemler en aza indirilmiştir. Önyargı değişkeni b ile temsil edilir. Denklem 2’deki x ve y değişkenleri, öznelitek değerlerini temsil eder ve bu denklem ile etiketleme işlemi gerçekleşir (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b).



Şekil 2.2. DVM sınıflandırma süreci; a) ikili sınıflandırma, b) çoklu sınıflandırma (Wu ve ark., 2018)

$$u = w \cdot x - b \quad (1)$$

$$y_i (w \cdot x_i - b) \geq 1, \forall i \quad (2)$$

2.2.2. K-En Yakın Komşuluk

EYK algoritması, basit, kolay anlaşılabilir olması ve yüksek performansa sahip olması nedeniyle çok kullanılan makine öğrenimi yöntemlerinden biridir (Assegie,

2021). Her test örneğinin ait olduğu tahmin edilmektedir. k 'nin pozitif bir tam sayı olduğu k en yakın komşuları arasında en yaygın olarak bulunan sınıfa, çoğu zaman k küçük olarak seçilir (Mushtaq ve ark., 2020). $k = 1$ ise, örnek bir özellik uzayında en yakın komşusu ile aynı sınıfa atanır. Kimyasal uygulamalarda tipik olarak moleküller olan örnekler, genellikle yüksek boyutlu olan özellik uzayında konum vektörleri olarak tanımlanır. Komşular, özellik uzayında mesafe bazında tanımlanır. Bu genellikle Öklid mesafesi olarak alınır, ancak Jaccard mesafesi gibi diğer metrikler de kullanılabilir. İkili sınıflandırma problemlerinde, k 'yi tek bir sayı olarak seçmek, oyların berabere kalma riskini azalttığı için yararlıdır, ancak uzayın ayrıştırma düzeyine bağlı olarak birden fazla komşu aynı mesafeyi paylaşabilir. Özellik alanındaki etiketlenmiş örnekler ve konumları mevcut olduğunda, açık bir eğitim aşaması gerekli değildir. Bu nedenle, EYK bir 'tembel öğrenme' algoritması olarak kabul edilir (Xu ve ark., 2021).

YZ ile ilgili teknolojiler, tıp alanında günümüz tarama yöntemlerinden daha iyi performans gösteriyor. Kardiyak aritmiyi tespit etmek için EKG adımlarının sınıflandırılması tıp alanında büyük önem taşımaktadır (Pharswan ve Singh, 2020). EYK algoritması, denetimli örnek tabanlı bir öğrenme algoritmasıdır. Bu basitliği ve önemli sınıflandırma da ki yüksek performans nedeniyle veri madenciliği ve istatistik biliminde popülerdir. Ancak olumsuz noktalarından biri de, örneklem boyutu ve öznelilikleri büyük olduğunda EYK algoritması sınıflandırma da karmaşık hale gelir. Bu durum da performansı azaltabilir.

EYK sınıflandırıcı, etiketlenmemiş gözlemleri en benzer etiketli örneklerin sınıfına atar ve sınıflandırmayı bu şekilde gerçekleştirir. Eğitim ve test veri seti için özellikler toplanır. Bunları 2B bir zemin üzerinde göstermek amacıyla iki özellik kullanılmış. Gerçekte bu özellik sayısı genişletilebilir. Klasik olarak yaklaşmak gerekirse, meyveler sebzelerden daha tatlıdır. Tahıllar ne gevrek ne de tatlıdır. Yapılan çalışmalar tatlı patatesin hangi kategoriye girdiğini tespit etmektir.

Görüntü sınıflandırmanın temel amacı, bir özellik setinin vektörleri ile tespit edilen bir nesneyi sınırsız olmayan bir veri setinden birine bağlamaktır. EYK algoritması, basit ve uygulanabilirliği kolay olduğu için en yaygın kullanılan sınıflandırma algoritmalarından biridir. Genellikle çeşitli alanlarda temel sınıflandırıcı olarak kullanılır (Cherif, 2018).

EYK algoritması parametrik olmayan bir yöntemdir. Çevrimdışı eğitime ihtiyaç duymayan bir tür tembel öğrenme algoritmasıdır. Bu algoritma, en yakın komşularını belirlemek ve çıktısını üretmek için test örneği ile tüm eğitim verileri arasındaki

mesafeyi hesaplayarak tüm eğitim örneklerini direkt olarak arar ve hesaplamayı yapar (Eyupoglu, 2018).

En basit şekilde, test örneğine en yakın k komşusundan hesaplanan ortalama değeri alması için özellik atanarak elde edilir. Ancak, ortalamaya en fazla katkıda bulunan en yakın komşu ve en az katkıda bulunan k . komşu olan komşuların katkılarını ağırlıklandırmaya yardımcı olabilir; bunu yapmak için bir prosedür Nigsch ve diğerleri tarafından yayınlandı. Bu, sayılan komşu örnekler ile komşu olmayan örneklerin yok sayılması arasındaki geçişi etkili bir şekilde yumuşatır.

EYK algoritması, veri yapısına duyarlıdır. Bu nedenle, protein fonksiyon tahmininde olduğu gibi, güçlü lokaliteye sahip özelliklerin hesaplanması için idealdir.70 Eğer test dizisine %90 özdeşliğe sahip tek bir komşu bulunursa, fonksiyonel etiketin güvenli bir şekilde olması kuvvetle muhtemeldir. Yerel olmasına rağmen EYK, özellik alanı boyunca dağıtıldığı sürece yerel olmaktan çıkıp küresel kapsama girebilir. Prensipte, komşulara olan mesafe veya belirli bir etikete sahip komşuların oranları, pratikte nadiren yapılmasına rağmen, tahmin güvenini ölçmek için kullanılabilir.

EYK tahmin yöntemi denetimli öğrenme modelindeki sınıflandırma ve regresyon algoritması olarak adlandırılır. Kolay uygulanabilirliği, matematiksel hesaplaması basit bir temele sahip pek çok farklı alanda tahmin modelleri bu yöntemin kullanılmasını arttırmıştır. Geçmişe dayalı incelemelere bağlı kullanılan eğitim setiyle her modelin değişkenliği belirlenir. Sınıflandırma işleminde, veri özelliklerine benzer özellikler aynı sınıf içinde etiketlenir. Bu hesaplanırken örnek veri öznitelikleri rastgele seçilir ve örnek veri özniteliklerine göre diğer veri özniteliklerinin uzaklıkları hesaplanır. Sonuç olarak, her özellik için en yakın komşu özellik sayısına (en fazla) bakılır. Burada parametre genellikle $\{2, 3, \dots\}$ değerler seçilir (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b). Bu yöntem genellikle iki parametre gerektirir. İlk parametre, en yakın örnekleri tanımlayan yakınlık ölçüsüdür. İkincisi, ele alınacak örnek sayısı için bir üst sınırı ifade eden k değişkenidir (Rodrigues, 2018). Bu yöntemin dezavantajı, her bir özellik verisi için mesafe bilgisini tutmak için bir hafıza gereksinimine ihtiyaç duymasındır. Özellikler arası mesafe ölçümü için yaygın olarak Öklid yöntemini kullanır (Niwatkar, & Kanse, 2020). Öklid formülü ile uzaklık (d) Denklem 3'e göre hesaplanır. Burada p ve q değişkenleri özellikleri temsil eder.


$$d(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2} \quad (3)$$

EYK algoritmasında kaç tane komşunun seçileceği sorusu önemlidir. Bunu belirleyen k parametresidir. En uygun komşu seçimi EYK algoritmasının performansı üzerinde önemli bir etkiye sahiptir. Rastgele seçilen büyük bir k değeri hatanın neden olduğu varyansın etkisini azaltır ama bu durum riskte taşır. En uygun k değeri seçmenin temel ölçütü, fazla ve eksik takma arasında bir denge kurmaktır (Harefa ve ark., 2017)

Komşu sayısının belirlenmesi için modelin optimizasyonunun sağlanması gerekir. Mesafe değeri arttıkça hesaplama adımı artsa da eğitim setindeki karmaşıklığı azaltacak ve test verisine uyumu arttıracaktır. Sınıflandırma problemi karşısında, iki sınıfa ayrılmış olan verilerden komşu sayısına bağlı olarak bir eğitim işlemi gerçekleştirilmektedir. Eğitimin amacı optimum mesafeyi belirlemektir. Regresyon problemleri karşısında ise, tahmininin yapılmasını istediği bağımlı değişken değeri tahmin eden bağımsız değişkenin en uygun sayıdaki komşu bağımsız değerlerinin bağımlı olan değerlerinin aritmetik ortalaması alınarak hesaplanmaktadır.

2.2.3. Lineer Diskriminant Analizi

Veri setlerinin sınıflandırılması için başta Temel Bileşen Analizi (TBA) ve doğrusal ayırmacılık analizi olmak birçok teknik vardır. LDA, sınıflandırmanın eşit olmayan frekansları ve performanslarının rastgele oluşturulmuş test verileri üzerinde inceleme yapar (Zhang ve ark., 2020). Orijinal veri kümeslerinin konum ve şekilleri farklı bir uzaya dönüştüğünde değişim gösterirken LDA'nın konumu sabit kalır ve daha fazla ayırım sağlar ve bunun yanında verilen sınıflar arasında bir karar bölgesi çizer.



Şekil 2.3. Orijinal veri setleri ve test vektörleri

Araştırmacılar genellikle bireylerin psikolojik tahminlerine dayalı sınıflandırmasıyla ilgilenirler. Böyle bir amaç için çeşitli modeller mevcuttur, ancak hangi modelin en iyi uygulama olarak kabul edildiği verilerin özelliklerine bağlıdır. EYK algoritması, DVM’ler Lojistik Regresyon (LR) gibi yöntemler LDA’ dan daha iyi performans gösterememiştir. Bu Eğitimin amacı, mevcutta temel düzeyde istatistiksel eğitime sahip olan araştırmacılara LDA'ya genel bir bakış ve bunun uygulanması ve yorumlanmasına ilişkin bir örnek sunmaktır. Bir LDA yöntemi uygulanırken kararlar verilmesi gerekiyor. Bu kararlar verildikten sonra olayın sınıflandırılmasını ve genel sınıflandırmayı değerlendirme yöntemleri tartışılmaktadır. Verilerin tahmini için LDA, orijinal türevinin aksine, modern bir Bayes penceresinden tanımlanmaktadır. Örneğin, klinik psikologlar, danışanlarının psikolojik özellikleri (örneğin, stres toleransı, kaygı ve özgüven) ile tedaviye uyumları (örneğin, çoğu seansı kaçırma, birkaç seansı kaçırma veya kaçırılma); LDA, tedavi uyumuna en çok hangi psikolojik özelliklerin katkıda bulunduğunu belirlemek ve aynı zamanda gelecekteki danışanlar arasında tedavi uyumunu tahmine dayalı olarak sınıflandırmak için bu özellikleri kullanmak için bir model formüle etmek için kullanılabilir. Fisher her iki amaç için de aynı yöntemi kullandı, ancak LDA daha sonra tahminde kullanılmak üzere değiştirildi. Tanımlama (ayrımcılık veya ayırma olarak da adlandırılır) ve tahmin (sınıflandırma veya tahsis)

arasındaki bu ayrım göz önüne alındığında, bazı araştırmacılar iki yöntemi de farklı şekilde adlandırmışlardır (Egwom ve ark., 2022).

Diskriminant analizi olarak adlandırılan DDA, LDA'nın bir değişken dizisiyle farklılıklarını tanımlamak için kullanılan yöntemle denir. Örneğin, istatistiksel olarak anlamlı çok değişkenli bir varyans analizinin takibi olarak uygundur (Egwom ve ark., 2022). Araştırmacı, her biri gruplar arasındaki değişkenliği açıklayan diskriminant puanları oluşturmak için kullanılan lineer diskriminant fonksiyonlarını (LDF'ler) tahmin eder. Ayrıca LDA, boyutu daha düşük verileri bir alanda görselleştirebilir ve LDF'lerin katsayılarını çizmek ve veri gruplarını en iyi şekilde ayıran ve boyutları anlamlandırmaya yardımcı olabilir.

Buna alternatif bir yöntem sunmak gerekirse bu yöntem LDA, sınıflandırması bilinmeyen yeni verilerin hangi grupta olmalarını tahmin etmek için kurallar geliştirilen kurallarda kullanıldığında, genel olarak tahmine dayalı bir diskriminant analizi elde edilir. Sınıflandırması bilinmeyen bir vakanın verileri, doğrusal sınıflandırma fonksiyonuna sunulur ve sonuçlar sınıflandırmayı tahmin etmek için kullanılır. Güncel bir örnek vermek gerekirse, travmatik bir durum yaşayan ergenlerden oluşan bir denklemde, düşük, orta veya yüksek şiddette travma sonrası stres bozukluğu semptomları gruplarına ayrılabilir. Daha sonra, benzer bir travmatik olay yaşayan bir çocuk için semptomun şiddetinin sınıflara ayrılması olayını tahmin etmek için bu geçmişte yaşanan vakalardan oluşan veri setleri kullanılarak türetilen bir tahmine dayalı model seti kullanılabilir.

LDA, sınıflandırma ve boyutları indirgemek için kullanılan kullanışlı bir modeldir. Yaygın olarak örüntü sınıflandırma sorunlarında özellikleri ayırmak için kullanılır. Bu durum ilk olarak 1936'da Fisher iki sınıfı ayırmak için lineer diskriminantı formüle etti ve daha sonra 1948'lerde CR Rao bu durumu çoklu sınıflarda kullanmaya başladı ve yapıyı genişletti. LDA, sınıflar arasındaki değişkenliği en üst seviyeye taşıyarak ve sınıflar içindeki değişkenliği azaltacak şekilde verileri D boyutlu bir özellik alanından bir D' ($D > D'$) boyutlu uzaya yansıtmak şeklinde düzenlenmesini sağladı.

Diskriminant Fonksiyon Analizi ise, denetimli sınıflandırma sorunlarında çok yoğun kullanılan bir boyut azaltma tekniğidir. Sınıflardaki değişkenlikleri modellemek için daha çok kullanılır. Boyutu yüksek olan uzaydaki nesneleri daha düşük boyutlu uzaya yansıtmak için kullanılır.

Son arařtırmalar, elle yazılmıř desenleri, ses sinyallerini, fizyolojik sinyalleri, yuruyuř analizi iin giyilebilir sensrleri vb. analiz etmek iin makine rğrenimi ve veri madencilięi yaklařımlarına dayalı farklı teřhis sistemler geliřtirilmiřtir. Bununla birlikte, bu farklı analitik yntemler arasında, konuřma verilerinin tespiti iin bazı avantajları nedeniyle konuřma kaydına dayalı yntemler rneli rde dikkat ekmiřtir. M algoritmalarının oęu, dengesizlik sınıflarına karřı olduka hassastır ve bu durumda M'nn en temel sorunlarındanr. Ek olarak, bu veri setinde uygulanan yntemlerin oęu, denek akıřmasına neden olan geleneksel k-katlı apraz doęrulamayı kullanmıřtır.

eřitli kaynaklardan yapılan arařtırmalara gre arařtırmacılar, LDA ile beslenen M modellerini geliřtirmiř ve farklı saęlık sektrndeki yařanan problemlerde en yaygın kullanılan geliřmiř performansı elde ettięi grlmřtir. rneklendirmek gerekirse, řengr, boyut indirgeme sorunu iin LDA'yı ve sınıflandırma problemi iin uyarlanabilir nano-Bulanık ıkarım Sistemi'ni (BS) kullanan LDA_ BS adlı bir sistem geliřtirmiřtir (řengr, 2008). Bu sistem ile kalp kapak hastalıęı tespitinde neredeyse %96'lık bir duyarlılık ve %94 rzgllk oranına ulařmıřtır. Doęantekin et al. ayrıca hepatit hastalıęının sınıflandırılması iin LDA-BS'nin uygulanabilirlięini kontrol etti ve %94.16'lık bir doęruluk elde etti (Dogantekin ve ark., 2010). Subařı ve Grsoy, epilepsi tespitini otomatikleřtirmek iin boyut azaltma iin LDA ve sınıflandırma iin SVM kullanan kademeli bir sistem geliřtirdi (Subasi ve Gursoy, 2010). alıřır ve Doęantekin, boyutsallık azaltma iin LDA'yı ve diyabetin otomatik sınıflandırması iin dalgacık tabanlı DVM'yi kullanan LDA-WSVM'yi geliřtirdi (alıřır ve Doęantekin, 2011).

Birden fazla ses veya fonasyon verisi tr cinsiyet aısından dengesizdir. Veri setinin birok rzellięi cinsiyete baęlı olmaktadır. Bu sebepten rtrr, oklu ses verileri zerine uygulanan makine rğrenimi yaklařımları hala zorluklar yařamaktadır. Burada bazı aıklıklar bulunmaktadır. Karřılařılan bu problemleri zmek iin; boyut azaltma sorunu iin LDA, sınıflandırma sorunu iin NN, optimizasyon sorunu iin GA kullanan LDA-NN-GA adlı hibrit akıllı sistemleri uzmanlar rnermektedir. Ayrıca, eęitim verilerinde daha iyi performans gsterebilecek ve test verilerine genelleřtirebilecek bir model elde etmek iin, genetik olarak optimize edilmiř en iyi K modeli elde etmek iin optimizasyonu K-zamanları iin GA zerinden tekrarlıyoruz. Son olarak, eęitim veri tabanında ve test veri tabanında iyi performans gsteren, yani daha iyi genelleme yeteneklerine sahip olan modeli seiyoruz. Ek olarak, cinsiyete baęlı rzelliklerin

etkisinden kaçınmak için, önerilen sistemi cinsiyete bağlı özellikler kullanmadan özellik setinde simüle edilebilmektedir.

- Parkisyon hastalığında ilk defa kullanılan LDA-NN-GA sistemi uygulandı.
- Çoklu fonasyon verilerinin özelliklerinin kullanılması eski yöntemlerle kıyas edildiğinde çok daha yüksek performans sağladığı görülmüştür.
- Ayrıca, bu çalışmada oluşturulan model, daha önce önerilen modellerde gözlenmeyen bir özellik olan genelleme yeteneklerine sahiptir.
- Literatürde geçmişte parkisyon hastalığının tespiti için yaygın olarak kullanılan çok sayıda fonasyon verisindeki potansiyel bir sorunu vurguluyoruz. Özellik alanı cinsiyete bağlı birçok özellik içerirken veriler cinsiyet açısından dengesizdir. Bu nedenle, çalışmalarda cinsiyete bağlı özellikleri ortadan kaldırarak yeni deneyler de yapılmıştır.

Örneklendirmek gerekirse, iki farklı sınıfımızın olduğunu düşünelim ve bunları verimli bir şekilde ayırmamız gerekiyor. Sınıfların birden fazla özelliği olabilir. Bunları sınıflandırmak için yalnızca tek bir özelliğin kullanılması, aşağıdaki şekilde gösterildiği gibi bazı çakışmalara neden olabilir. Bu nedenle, uygun sınıflandırma için öznelik sayısını artırmaya devam edeceğiz.

Diskriminant analizi, önceden belirlenen sayıda özelliğe sahip birimlerin doğal ortamdaki gerçek sınıflara atanmasını amaçlayan çok değişkenli bir istatistiksel bir yöntemdir (Beck ve Sharon, 2022). Diskriminant analizinde hem sınıflandırma ve bunun yanında boyut indirgeme yöntemlerini içerir. Diskriminant analizlerinin en popülerleri LDA'dır. Bu popülerlik çok sınıflı etiketleri ayırmak için en iyi yöntemi sunmaktadır (Mandelkow ve ark., 2016).

Bu çalışmanın sınıflandırma sürecinde kullanılan MÖ yöntemleri (DVM, EYK, LDA), hazır araç kutuları kullanılarak derlendi. MÖ yöntemlerinin parametre değerleri, varsayılan değerlerden oluşmuştur (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b).

2.3. Derin Öğrenme

DÖ, YSA gibi algoritmaların kullanıldığı bir MÖ yöntemidir. Bu yöntemde, büyük veri kümeleri kullanılarak çok katmanlı YSA oluşturularak veriler üzerinde öğrenme yapılır (Niu ve ark., 2021). DÖ, temel olarak birçok katmanın birbirine

bağlandığı bir sinir ağı oluşturulması ve bu ağın, öğrenme süreci boyunca, verileri anlamaya çalıştığı bir yöntemdir. Bu ağlar, verileri daha iyi anlayarak, daha doğru sonuçlar üretirler (Guo ve ark., 2016).

DÖ hayatımızda giderek daha önemli bir rol oynamaktadır. GÖ, YZ alanında bir devrim yaratmıştır. Görüntü ve konuşma tanıma, doğal dil işleme, otonom araçlar, sağlık, finans ve daha fazlasını içeren çok çeşitli uygulamalarda kullanılmaktadır (Dong ve ark., 2021; Kamilaris ve Prenafeta-Boldú, 2018). DÖ, özellikle görüntü işleme, doğal dil işleme ve ses tanıma gibi alanlarda oldukça başarılı sonuçlar vermektedir (Niu ve ark., 2021; Litjens ve ark., 2017). DÖ gelişmeye devam ettikçe, yeni uygulamalara olanak tanıyarak, mevcut olanları da iyileştirerek hayatımızda daha da büyük bir rol oynaması muhtemeldir.

2.4. Evrişimli Sinir Ağları

ESA, genellikle görüntü işlemede kullanılan bir DÖ modelidir. Bu model, özellikle görsel veri gibi yapısal verilerin analizinde çok etkilidir (Rawat ve Wang, 2017). ESA'lar, YSA ailesine aittir. Girdi olarak aldıkları görüntü verileri, çok katmanlı sinir ağlarından oluşan bir mimariye sahip bir işlem birimi içinde işlenir. Bu mimaride, önceki katmanlarda bulunan filtreler, sonraki katmanlarda bulunan filtreler tarafından işlenir ve daha yüksek seviyeli özellikler çıkarılır (Gu ve ark., 2018). ESA'lar, DÖ uygulamalarında çok kullanılır. Özellikle; görüntü sınıflandırma, nesne tanıma, yüz tanıma ve nesne tespiti gibi alanlarda başarıyla kullanılmaktadır (Dhillon ve Verma, 2020; Ajit ve ark., 2020). Bu başarının arkasındaki neden, ESA'ların verilerdeki özellikleri kendiliğinden çıkarabilme yeteneğine sahip olmalarıdır. Bu sayede, verilerin özelliklerini elle tanımlamak veya çıkarmak yerine, MÖ algoritmasının otomatik olarak özellikleri bulması sağlanır.

ESA'ların bir diğer avantajı da veri örüntülerinin uzamsal yapılarını koruyabilme özelliğidir. Bu özellik, görüntülerin, ses kayıtlarının veya diğer yapısal verilerin bir bütün olarak analiz edilmesine olanak sağlar. Bu da, özellikle görüntülerdeki nesnelerin yerini ve oryantasyonunu tespit etmek gibi görevlerde çok etkilidir (Mittal ve ark., 2019).

Bir ESA mimarisindeki katmanlar şu şekilde verilebilir; giriş katmanı, evrişim katmanı, havuzlama katmanı, tam bağlantılı katman ve çıkış katmanı.

2.4.1. Giriş Katmanı

ESA’da giriş katmanı, ağa girdi olarak verilecek olan verilerin boyutunu ve şeklini belirler. Giriş katmanı, verileri ağın geri kalanına uygun hale getirmek için kullanılan ilk işlem adıdır. Bu katman, verileri tensör şeklinde alır ve ağın geri kalanındaki diğer katmanlarda işlem yapmak için uygun hale getirir (Ajit ve ark., 2020).

Giriş katmanı, girdi verilerinin özelliklerine göre değişebilir. Örneğin, görüntü işleme uygulamalarında, giriş katmanı 3B bir tensör şeklinde olabilir. Bu tensör, görüntünün genişliği, yüksekliği ve kanal sayısı (RGB veya siyah-beyaz) gibi özellikleri içerir. Metin sınıflandırma gibi başka bir uygulama için, giriş katmanı 1 boyutlu bir tensör şeklinde olabilir ve kelime vektörleri veya tek tek karakterler gibi verileri içerebilir (Sahu ve Dash, 2021).

Giriş katmanı ayrıca veri normalizasyonu, veri ölçeklendirme veya veri standartlaştırma işlemlerinin de yapılabildiği bir yerdir. Verilerin özelliklerine bağlı olarak, giriş katmanı farklı şekillerde uyarlanabilir veya özelleştirilebilir (Dhaka ve ark., 2021).

2.4.2. Evrişim Katmanı


Evrişim katmanı, ağın öğrenme yeteneğini artıran, görüntü işleme ve diğer yapısal veri işleme uygulamalarında yaygın olarak kullanılan bir katmandır (Ajit ve ark., 2020). Bu katman, girdi verilerindeki özellikleri belirleyerek, bu özellikleri filtreler aracılığıyla çıkarır. Evrişim katmanı, girdi verilerindeki özellikleri belirlemek için bazı filtreler kullanır (Albawi ve ark., 2017). Bu filtreler, belirli bir boyutta hareket ederek, girdi verilerindeki her özellik bölgesine uygulanır. Örneğin, bir görüntüdeki kenarları belirlemek için bir filtre kullanılabilir. Bu filtre, görüntüdeki her piksel bölgesine uygulanarak kenarların yerini belirleyebilir.

Evrişim katmanı, evrişim işlemi adı verilen matematiksel bir işlemi kullanarak, filtrelerin girdi verileri üzerinde uygulanması işlemini gerçekleştirir (Altameem ve ark., 2022). Evrişim işlemi, her bölgedeki özelliklerin ağırlıklı toplamını hesaplar ve bu toplamı özellik haritasına aktarır. Evrişim işlemi Denklem 4’te gösterilmiştir (Başaran, 2020).

$$(f * h)[m, n] = \sum_j \sum_k h[j, k] f(m - j, n - k) \quad (4)$$

Denklemdede; giriş görüntüsü f , kernel h , m ve n de çıkış matrisinin satır ve sütun indisleri, evrişim işleminden sonra yeni matrisin satır ve sütunu da j ve k ile ifade edilmektedir.

Evrişim işlemi girdi verileri boyutunu korurken, verilerdeki özellikleri çıkarmaya yardımcı olur. Bu katman, ağı eğitimi sırasında öğrenilebilen filtreler kullanır ve bu filtreler, ağı öğrenme yeteneğini artırarak daha iyi sonuçlar elde etmeye yardımcı olur. Ayrıca, birden fazla evrişim katmanını bir araya getirilerek daha karmaşık özellikler elde edilebilir. Evrişim katmanında örnek bir görüntüye, filtre uygulanarak özellik çıkarma işlemi Şekil 2.4.' te gösterilmiştir.




Şekil 2.4. Evrişim katmanında özellik çıkarma işlemi (Başaran, 2020)

Evrişim katmanı girdi görüntüsünden evrişim çekirdekleri kullanarak özellik haritaları üretir. Bu özellik haritaları daha sonra bir aktivasyon fonksiyonuna (örneğin ReLU) uygulanarak aktivasyon haritaları oluşturulur (Dey ve ark., 2022). Aktivasyon haritaları, özelliklerin daha yüksek seviyede temsil edildiği bir düzlemdir. Bu haritalar, daha sonra bir sonraki evrişim katmanına veya tamamen bağlı katmana aktarılabilir.

2.4.3. Havuzlama Katmanı

Havuzlama katmanı, genellikle evrişim katmanlarından sonra kullanılır. Bu katman, özellikle boyut azaltma amaçlı olarak kullanılır ve girdi özellik haritasının boyutunu küçültür (Oza ve ark., 2022). Böylece, daha az parametre ile daha derin ve karmaşık modeller elde edilebilir. Havuzlama katmanı, özellik haritalarının boyutunu azaltarak hesaplama yükünü azaltır ve aşırı öğrenmeyi azaltarak daha iyi bir genelleştirme sağlar. Ayrıca, girdi özellik haritasındaki hafif değişikliklere karşı hassasiyeti azaltır ve özelliklerin öğrenilmesine katkıda bulunur.

Havuzlama katmanı, üç tür işlem yapar: maksimum, ortalama ve minimum havuzlama (Agnes ve ark., 2020). Maksimum havuzlama, havuzlama bölgesindeki en büyük ögeyi seçerek boyut azaltma işlemini gerçekleştirir. Bu yöntem, en sık kullanılan yöntemdir. Maksimum havuzlama, her bir havuzlama bölgesindeki en büyük ögeyi seçer ve bu öğeleri çıkış özellik haritasında tutar. Havuzlama bölgesi boyutu ve adım uzunluğu, özellik haritasının boyutunu azaltmak için kullanılır. Ortalama havuzlama, havuzlama bölgesindeki öğelerin ortalamasını alarak boyut azaltma işlemini gerçekleştirir. Ortalama havuzlama, her bir havuzlama bölgesindeki öğelerin ortalamasını alarak boyut azaltma işlemini gerçekleştirir (Zhang ve ark., 2021). Ortalama havuzlama, maksimum havuzlama ile benzer şekilde özellik haritalarının boyutunu azaltarak hesaplama yükünü azaltır ve aşırı öğrenmeyi önleyerek daha iyi bir genelleştirme sağlar. Ancak, maksimum havuzlama yöntemi, genellikle daha iyi sonuçlar verir. Minimum havuzlama, havuzlama bölgesindeki öğelerin en küçüğünü seçerek boyut azaltma işlemini gerçekleştirir (Melekoodappattu ve ark., 2022). Bu yöntem, genellikle diğer iki yöntemden daha az kullanılır. Çünkü en küçük öğenin seçilmesi, veri kaybına ve özelliklerin kaybedilmesine neden olabilir. Minimum havuzlama yöntemi, aşırı öğrenmeyi önleyerek daha iyi bir genelleştirme sağlamaya yardımcı olabilir. Ancak, özelliklerin kaybedilmesine ve veri kaybına neden olduğu için diğer iki yöntem kadar yaygın değildir. Şekil 2.5' te 3x3'lük bir filtre kullanılarak maksimum, minimum ve ortalama havuzlama yöntemlerinin uygulaması gösterilmiştir.



Şekil 2.5. 3x3'lük bir filtre kullanılarak maksimum (a), minimum (b) ve ortalama (c) havuzlama yöntemlerinin uygulanması (Serin, 2020)

2.4.4. Tam Bağlantılı Katman

Tam bağlantılı katman, YSA'nın en temel katmanlardan biridir (Zhang ve ark., 2021). Bu katman, önceki katmanlardaki tüm nöronlarla bağlantılıdır ve her nöronun çıkışı, sonraki katmana giriş olarak sağlanır. Bu nedenle, bu katmanın her bir nöronu, giriş verilerindeki tüm özelliklere bakar ve bunları bir ağırlık matrisi ile çarparak çıkışı üretir (Desai ve Shah, 2021).

Veriye özgü özellikleri öğrenmek, sınıflandırma, regresyon veya diğer görevler gibi çeşitli işlemler gerçekleştirmek için kullanılabilir. YSA da girdi verilerinin boyutu çok büyük olduğunda, önceki katmanlarda özelliklerin çıkarılmasından sonra, bu özelliklerin sonucu olan daha düşük boyutlu bir vektörü tam bağlantılı katmana besleyerek, modelin öğrenmesini kolaylaştırır (Shah ve ark., 2022).

2.4.5. Çıkış Katmanı

Çıkış katmanı, genellikle sınıflandırma veya regresyon problemleri için kullanılır (Desai ve Shah, 2021). Katmanın yapısı, yapılacak işleme ve çıktının formatına bağlıdır. Regresyon için, çıkış katmanı genellikle doğrudan çıktı değerlerini verir. Örneğin, bir regresyon probleminde, çıkış katmanı, tek bir sayısal değer veya vektör gibi hedef çıktıları üretebilir. Çıkış katmanı, aynı zamanda kayıp fonksiyonunu hesaplamak için de kullanılır (Ma ve ark., 2021). Kayıp fonksiyonu, ESA modelinin performansını ölçmek ve optimize etmek için kullanılır. Sonuç olarak, ESA'larda çıkış katmanı, modelin amacına ve kullanılan veri setinin formatına bağlı olarak değişebilir.

2.5. Transfer Öğrenme Modelleri

Transfer öğrenme, bir öğrenme görevinden diğerine bilginin aktarılmasıdır. Bu yaklaşım, önceden eğitilmiş bir modelin, bir başka görev veya veri kümesi için uyarlanması yoluyla gerçekleştirilebilir. Önceden eğitilmiş bir ESA modeli, özellikle büyük veri setleri üzerinde eğitildiğinde, görüntülerin belirli özelliklerini tanımlama konusunda oldukça başarılı olabilir. Transfer öğrenme, önceden eğitilmiş bir modelin bu özelliklerinin, bir başka görev veya veri kümesi için kullanılmasıdır (Alzubaidi ve ark., 2020).

Önceden eğitilmiş bir model, özellikle evrişim ve havuzlama katmanlarından oluşan özellik çıkarma bölümü, yeni bir görev veya veri kümesi için yeniden kullanılabilir. Bu, daha az veriyle çalışmak zorunda kalan ve daha kısa sürede daha yüksek performans elde etmek isteyen uygulamalar için oldukça yararlıdır (Samala ve ark., 2018).

Transfer öğrenme, ayrıca öğrenme görevleri arasında benzerlikler olduğunda özellikle etkilidir. Örneğin, yüz tanıma görevinde eğitilmiş bir model, özel bir yüz tanıma görevi için transfer edilebilir. Bu, daha az eğitim verisi kullanılarak yüksek doğruluk sağlayabilir (Jin ve ark., 2020). Transfer öğrenme modelleri, ESA gibi DÖ yöntemlerinde oldukça yaygın olarak kullanılmaktadır ve özellikle sınırlı eğitim verisi bulunan uygulamalarda oldukça yararlıdır (Ribani ve Marengoni, 2019; Ali ve ark., 2021).


Bu çalışmada, transfer öğrenme modelleri olan AlexNet, ResNet ve GoogleNet modelleri açıklanmıştır.

2.5.1. ResNet

ResNet, 2015 yılında Kaiming He ve arkadaşları tarafından geliştirilen bir ESA modelidir (Erwandi ve Suyanto, 2020). ResNet, derin sinir ağlarının derinliği arttıkça ortaya çıkan aşırı uyum sorununu çözmek için özelleştirilmiştir. ResNet, blok adı verilen modüllerden oluşur. Bloklar, birbiri ardına bağlı katmanlardan oluşur ve her blokta, girdi ve çıktı arasına, katmanların çıktısını birbirine ekleyen bir bağlantı vardır. Bu bağlantı, bloklar arasındaki akışı kolaylaştırır ve modelin derinliği arttıkça aşırı uyumu azaltır (Ferreira ve ark., 2018).

ResNet, ESA'nın diğer modellerinden farklı olarak, küçük filtre boyutlarına sahip evrişim katmanları kullanır. Bu yaklaşım, daha az parametre kullanarak modelin hafızasını azaltır ve daha az eğitim verisi ile daha yüksek doğruluk sağlar (Chapala ve Sujatha, 2020).

ResNet, ImageNet veri kümesinde eğitilerek, görüntü sınıflandırma, nesne tespiti ve yüz tanıma gibi birçok görüntü işleme görevinde yüksek doğruluk elde etmiştir (Reenadevi ve ark., 2021; Vo ve ark., 2019; Peng ve ark., 2020). Ayrıca, ResNet modelleri, transfer öğrenme yöntemi ile farklı görevlerde kullanılabilen popüler modeller arasındadır. ResNet mimarisinin yapısı Şekil 2.6' da gösterilmiştir.




Şekil 2.6. ResNet mimarisi (Türk ve ark., 2019)

Şekil de ResNet mimari yapısı gösterilmiştir. $H(x)$ fonksiyonunu öğrenirken, ağırlık her katmanında, bir önceki katmandan geçen bilginin direkt olarak sonraki katmana aktarılması sağlanır. Bu şekilde, derin ağlarda ortaya çıkan geriye doğru yayılan gradient sorunlarının önüne geçilir.

2.5.2. AlexNet

AlexNet, 2012 yılında Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilen bir ESA modelidir. AlexNet, ESA'nın yükselişini başlatan bir dönüm noktası olarak kabul edilir (Arora ve ark., 2020).

AlexNet, 8 katmandan oluşur. 5 ESA katmanı, 2 tam bağlantılı katman ve bir çıkış katmanı içerir. Ayrıca, ReLU aktivasyon fonksiyonu, maksimum havuzlama katmanları ve normalizasyon katmanları kullanılarak tasarlanmıştır. AlexNet mimarisi Şekil 2.7' de sunulmuştur.



Şekil 2.7. AlexNet mimarisi (Krizhevsky ve ark., 2017)

3. KAYNAK ARAŞTIRMASI

Çeşitli MÖ algoritmaları kullanılarak meme kanserini teşhislerinin performansları incelenerek doğruluk oranları kıyaslanmıştır. Hazırlanan çalışma da etkin olan genler tespit edilip, %90,72'lik bir başarı oranı sağlanmıştır (Adem, 2020).

Beyin MR görüntülerinde tespit edilen alanların öznitelik kullanarak yeniden oluşturulması ve sınıflandırılması üzerine geliştirilen çalışma da BDTS ile 10 hastaya ait 497 kesit görüntüden oluşan REMBRANDT veri kümesiyle yapılan sınıflandırma ile karar ağaçları %93,36, YSA ile %94,89, EYK algoritması ile %96,93 ve Meta Learner algoritması ile %96,93 doğruluk oranlarına ulaşılmıştır (Osman, 2018). Elde edilen sonuçlar ile MR görüntülerinden beyin tümörü tespitinde sınıflandırma işleminin yüksek performans sağladığı gözlemlenmiştir.

Mikro kireçleme bölgelerinin tespitlerinin göz ile algılamının zor olduğu durumlarda gözden kaçırılması problemi olmaması için geliştirilen BDTS tasarlanarak 2B EWD yöntemi ve MWBSA yöntemleri kullanılarak elde edilen sonuçlar MIAS veri tabanı ve DDSM veri tabanı kullanan diğer çalışmalarla hassasiyet değerleri açısından karşılaştırıldığında 0,90 , 0,94 , 0,93 ve 0,96 hassasiyet değerlerine ulaşılmıştır. Elde edilen sonuçlar ile mikro kireçleme tespiti açısından en iyi sonucun MWBSA yöntemi tarafından verildiği görülmüştür (Mescher, 2013).

Meme kanseri imgelerini iyi ve kötü huylu olarak sınıflandırma için ResNet-50 mimarisi üzerine yapılan çalışmada ESA tabanlı ResNet-50 mimarisinin eğitimde transfer öğrenme yöntemi uygulanarak elde edilen sonuç ile literatürde ki mevcut çalışmalara kıyasla daha yüksek bir verim alınmıştır. Ayrıca önerilen metot ile meme kanseri iyi huylu veya kötü huylu durum tespitinde herhangi bir ön işlem yapılmadan verileri otomatik olarak sınıflandırmaktadır (Spanhol ve ark., 2015).

Meme Kanseri Wisconsin Veri Kümesindeki göğüs kanseri hastaları üzerinde yapılan çalışmada eğitici ve eğitici olmayan nöral algoritmalar meme kanseri teşhisi için karşılaştırılmıştır. Sonuçlara bakıldığında RBF ve SOM modelleri sinir ağı için en uygun modeller olmuştur. Bu sonuçlar nöral algoritmaların meme kanseri teşhisindeki önemli başarılar elde ettiği görülmüştür (Muzaki, 2020).

Bu çalışmada Wisconsin göğüs kanseri veri kümesi üzerine veri madenciliği metotlarının uygulanmasıyla başarı ölçütlerine göre sonuçları karşılaştırmıştır. J48 algoritması Karar Ağacı Algoritması (KAA), Naive Bayes, LR ve örnek tabanlı sınıflandırma algoritması olarak K-Star metotları WEKA çalışma ortamında

kullanılmıştır. Sonuç olarak, doğruluk değeri açısından LR algoritmasının diğer algoritmalarla karşılaştırıldığında oransal olarak daha yüksek performans aldığı gözlemlenmiştir (Poyraz, 2012).

Ahmad ve ark., çeşitli MÖ tekniklerini göğüs kanseri hastalığının iki yıl içinde yeniden ortaya çıkabilme durumunun tahmin edilmesiyle ilgili farklı bir çalışma yapmıştır (Ahmad ve ark., 2013). Çalışma Tahran Ulusal Kanser Enstitüsü veri tabanından alınan meme kanseri veri setini incelemiştir. Veri kümesinde eksik olan değerler Beklenti Maksimizasyonu algoritması kullanılarak düzenlenmiştir. MÖ yöntemlerinden sıkça kullanılan KAA, DVM ve YSA uygulanmıştır. Meme kanserinin yeniden nüksetmesinin tahmin edilmesi üzerine hazırlanan bu çalışmada çok yüksek bir doğruluk oranı yakalamış ve en az hata oranı DVM yönteminde elde etmiştir.

Iseri ve Oz, mamogram görüntülerine MÖ yöntemlerini uygulayarak meme kanserinin teşhis edilmesi üzerine bir çalışma hazırlamışlardır (Iseri ve Oz., 2014). Çalışma mamogram görüntülerindeki mikro kireçleme bölgelerinin tespiti ve ilgili bölgelerin kötü veya iyi huylu olma durumlarına göre sınıflandırılması olacak şekilde iki aşama da gerçekleştirmiştir. Matematik laboratuvarı (MATLAB) ortamında göğüs kanseri tespiti sistemi adı verilen (BCDS: Breast Cancer Detection System) bir uygulama geliştirmiştir. Dört adet özellik çıkarma yöntemi ile Çok Katmanlı Yapay Sinir Ağı ve DVM, sınıflandırıcı olarak göğüs kanseri ile alakalı başarılı tespitler amaçlanmıştır. 2014 yılında hazırlanan bu çalışmada kanser hastalığının erken tanısının konulabilmesi için veri madenciliği yönteminin uygulamalarının hastalığa etkisi araştırılmıştır. WEKA ortamında Wisconsin Göğüs Kanseri veri setine Bayes Ağı, Naive Bayes, Çok Katmanlı Algılayıcı, Basit Lojistik, Olasılıksal Gradyan İniş, Sıralı Minimal Optimizasyon, IB1, K-Yıldız, PART, Lojistik Model Ağaçları ve Rassal Ormanlar gibi çeşitli sınıflandırma yöntemlerini uygulamıştır. Sınıflandırma çıktıları karşılaştırıldığında Kappa istatistiği, doğruluk, kesinlik, duyarlılık, F-ölçütü ve ROC alanı gibi parametreler dikkat çekmiştir. 0,94 Kappa istatistiği, %97,40 doğruluk, 0,97 kesinlik, 0,99 duyarlılık 0,98 F-ölçütü ve 1,00 ROC alanı çıktılarına göre Basit Lojistik sınıflandırma yöntemi çok iyi sonuçlar vermiştir (Ragab ve ark., 2019).

Bektaş ve arkadaşları 2016 yılında hazırlamış oldukları çalışmada, meme kanserinin teşhisi için farklı MÖ algoritmaları kullanılmış ve bu algoritmaların başarı oranları karşılaştırılmıştır. Çalışmada %90,72 başarı oranını 139 öznitelik ile tespit etmiştir (Bektaş ve Babur., 2016).

Doğan ve ark., çalışmalarında MR görüntülerinde beyinde tespit edilen ilgili alanların öznelilikler kullanılarak görüntünün yeniden oluşturulması ve sınıflandırılması üzerine bir sistem geliştirmişlerdir. Geliştirilen sistemin aşamaları; önileme, tümör tespiti ve bölütleme olup, veri seti 10 hastaya ait ve 497 kesit görüntüden oluşmaktadır. Sistemin performansları sırasıyla; karar ağaçları, YSA, EYK ve Meta-Learner algoritması ile %93,36, %94,89, %96,93 ve %96,93 doğruluk oranları tespit etmişlerdir (Doğan ve ark., 2016). Bu çalışmada elde edilen sonuçlar ile önerilen yöntemin MR görüntülerinden beyin tümörü tespitinde sınıflandırma işleminin performansını arttırdığını tespit etmişlerdir (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b).

Turgut, yapmış olduğu çalışmada Python ortamında çeşitli MÖ yöntemlerini iki farklı mikro dizi meme kanseri veri kümelerine uygulamıştır (Turgut, 2017). Çalışmada öznelilik seçimleri yapılarak MÖ metotlarıyla yüksek doğrulukta tahmin yapılabilmesi amaçlanmıştır. Çalışmada DVM, YSA, k-EYK, Karar Ağaçları, Rastgele Orman, LR, Adaboost ve Gradyan Boosting Makina algoritmaları kullanılmıştır. İki meme kanseri veri kümesinde de öznelilik yöntemlerin uygulandıktan sonra en yüksek doğruluk DVM yönteminde, en düşük doğruluk Karar Ağaçları yönteminde elde edilmiştir. Ayrıca iki veri kümesinde de kullanılan aynı öznelilik yöntemleri çalışmada uygulanan tüm MÖ algoritmalarında birbirine yakın sonuçlar vermiştir.

Ganggayah ve ark., MÖ modellerini kullanarak meme kanseri hastalığından hayatın devamlılığını sağlayabilmek için önemli olan prognostik faktörleri belirlemeye çalışmışlardır (Ganggayah ve ark., 2019). DVM, Rassal Ağaç, YSA, Ekstrem Boost, LR ve KAA gibi pek çok MÖ algoritması çalışmada kullanılmıştır. Rastgele Orman yöntemi diğer yöntemlere oranla biraz daha yüksek performans sergilemiştir. Buna rağmen çalışmada kullanılan tüm algoritmalar birbirine yakın doğruluk değerleri vermiştir.

4. MATERYAL VE YÖNTEM

4.1. Veri Kümesi


BreaKHis veri tabanı, iyi ve kötü huylu meme tümörlerinin biyopsi görüntülerini içeren açık erişimli bir veri kümesidir. Görüntüler 2014 yılında Brezilya'daki P&D Laboratuvarında başlatılmış, klinik çalışma yoluyla toplanmış ve erişime sunulmuştur. BreaKHis veri tabındaki temel amaç, orijinal doku yapısını ve moleküler bileşimi koruyarak, varsa tümörün mikroskopta görünmesini sağlamaktır. Veri tabanında görüntü sabitleme, kurutma, temizleme, süzme, gömme ve düzeltme gibi adımları içermektedir (Mescher, 2013).

Görüntülerde 3 kanallı RGB olarak alınır ve her kanalda 8 bit derinlikte, taşınabilir ağ trafik formatında 700 x 460 piksel çözünürlükte kaydedilir. Görüntü PNG uzantılıdır. BreaKHis veri kümesi 4x, 10x, 100x, 200x, 400x büyütme faktörleri kullanılarak oluşturulmuştur. Ortaya çıkan görüntüler, normalleştirilmiş veya renk standartlarında olmayan ham görüntülerdir (Spanhol ve ark., 2015).

BreaKHis veri tabanı iyi ve kötü huylu toplam 7909 meme tümöründen oluşmaktadır. Çizelge 1.1'de bu görüntülerin dağılımları gösterilmiştir. İyi ve kötü huylu meme tümörü mikroskop ile tespit edilen birçok farklı tiplere ayrılabilir.

Bu çalışmada orijinal BreaKHis veri kümesinin 400x büyütme faktörü ile işlenmiş görüntü kümesinin belirli bir kısmı kullanılarak analizler gerçekleştirildi. 547 adet iyi huylu, 1146 adet kötü huylu olmak üzere toplam 1693 adet görüntü kümesinden oluşmaktadır (Muzaki, 2020). Yapılan deneysel analizlerde veri kümesinin dağılımı 0,7 oranında eğitim verisi ve 0,3 oranında test verisi olarak ayrılmıştır.

BreaKHis veri kümesinin sınıflarının temsil edildiği alt görüntü kümesi Şekil 4.1' de gösterilmiştir.



Şekil 4.1. BreakHis 400x veri kümesinin sınıfları; a) iyi huylu, b) kötü huylu


Klasik programlama dilleriyle görüntü işleme modellemeleri gerçekleştirmek kolay değildir. Bu sebeple görüntü işleme modellemelerine ait geliştirilen kütüphaneleri bu programlama dillerine eklenmiştir. MATLAB teknik bir programlama dilidir. Matematiksel çalışmalarından haberleşme sistemlerine, istatistikten finansal analizlere kadar çoğu uygulama ortamlarında MATLAB kullanılmaktadır. Bunun yanında MATLAB görüntü işleme sistemlerine yönelik birçok algoritma ve fonksiyona sahiptir. Bu algoritmalar ve mevcut fonksiyonlar sayesinde MATLAB görüntü işleme sistemlerinde çok tercih edilen uygulama geliştirme ortamlarından biri haline gelmiştir. MATLAB algoritma kurulup kodlama ile programlama yapılabilen uygulama geliştirilebilen bir platformdur (Wu ve ark., 2018).

4.2. Önerilen Hibrit Yaklaşım

Çalışmada önerdiğimiz yaklaşım, mikroskobik biyopsi görüntülerini kullanarak iyi huylu ve kötü huylu meme kanseri çeşitlerinin sınıflandırılmasını gerçekleştirmeye yarayan YZ tabanlı hibrit bir modeldir. Bu yaklaşım aynı mimariye sahip, artık bloklu modellerin paralel bir yapıda kullanılmasına dayalı geliştirilmiştir. Kullanılan 3 yeni model ile tam bağlantılı (TB) katmanları aynı sayı da öznitelik vermektedir. Bu modeller; ResNet-18, ResNet-50 ve ResNet-101'dir. Üç modele yeni bir TB tür sayısı katmanı ekleyerek, veri kümesinin tür sayısı kadar çıkışa TB tür sayısı = [tür sayısı x girdi sayısı] boyutunda öznitelik seti aktarılmaktadır. Örnek verecek olursak; iki sınıflı (iyi huylu ve kötü huylu) bir veri kümesinin transfer öğrenme tabanlı ResNet modelleri ile eğitim sürecinde TB katmanları tarafından işlem görmekte ve sınıflandırma işlemi öncesi oluşturulmuş, yeni tam bağımlı katman (TB_2) sayesinde $2x$ girdi veri sayısı boyutunda aktivasyon setleri oluşturulmaktadır. Buradaki amaç model maliyetini düşürmek ve verimliliği arttırmaktır. Toplam 3 ResNet modeli bu çalışmanın deneysel analizlerinde kullanıldı ve $3x$ ($2x$ girdi veri sayısı) kadar birleştirilmiş bir aktivasyon seti elde edildi. Ardından $6x$ girdi veri sayısı boyutundaki birleştirilmiş özellik seti yeniden softmax yöntemine girdi olarak verilerek sınıflandırma işlemi gerçekleştirildi. Ayrıca softmax'a alternatif olarak sınıflandırma işlemini başarılı bir şekilde gerçekleştirebilen makine öğrenme yöntemleri de (DVM, EYK, LDA) sınıflandırma sürecinde kullanıldı. Tür sayısı kadar aktivasyon seti verebilen TB katmanlar (TB tür sayısı), artık bloklu ESA modellerinin iş yükünü (zaman, hız maliyeti) azaltmayı sağlamıştır. TB tür sayısı katmanlarının birleştirilerek yeni bir özellik setinin oluşturulması ve yeniden makine

öğrenme yöntemleri ile sınıflandırılması işlemi de önerilen yaklaşımın sınıflandırma sürecine katkı sunmuştur. Önerilen modelin genel mimari yapısı Şekil 4.2’de verilmiştir (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b).





Şekil 4.2. Önerilen modelin genel mimari yapısı

4.3. Artık Tabanlı Derin Öğrenme Modelleri

Tıp ve endüstri gibi alanlarda çok büyük miktarda verinin üretildiği bir dönemi yaşıyoruz. Bu durum bizi verilerin analizlerine ve yorumlanmasıyla alakalı zorlukları beraberinde getirmektedir. Bu nedenle elde edilen verileri kullanılmasını sağlayabilecek MÖ ve YZ gibi yöntemlere ihtiyaç duyulmaktadır (Liu ve ark., 2021). Bu ihtiyacı giderebilmek için DÖ, en çok dikkat çeken ve çok yeni bir yöntemdir. DÖ makinelerinin gelişimi önümüzdeki yıllarda hız kazanması ve daha efektif olarak kullanım alanları oluşturması bekleniyor. Bu gelişim alanlarından biri olan sağlık alanında derin DÖ uygulamaları yalnızca bir görevi yerine getirme amacıyla değil diğer YZ uygulamalarından gelen bilgileri de kullanarak oluşturulması gereken uygulamayı eğitebilir. DÖ, mimari yapısıyla gizli evrişimsel katmanlar barındıran ve girdi verilerini alıp işleyip ve otomatik bir şekilde özniteliklerin çıkartılmasını sağlayan; sınıflandırma, regresyon, kategorize edebilme vb. işlemleri çıkış katmanına aktaran, YZ'nin bir alt dalıdır (Çalışkan ve ark., 2022b; Alsaggaf ve ark., 2020 ; Toğaçar ve ark., 2021). ES modellerinin genel yapısı evrişimsel katmanlar, havuzlama katmanları ve Tam Bağlantılı (TB) katmanlardan oluşmaktadır. Evrişimsel katman girdi verisinde genellikle evrişimsel katmanlardan sonra kullanılır ve girdi boyutunu düşürerek modelin daha kolay eğitilmesini sağlar. TB katmanı diğer katmanlardan elde edilmiş öznitelikleri bütünleştirerek girdi verilerinin çıkış işlemlerini gerçekleştirebilmek için olasılık tabanlı değerlerin oluşmasına yardımcı olur (Başaran, 2022; Çalışkan ve ark., 2022b).

Derin sinir ağları, büyük makine öğrenimi algoritmalarının güç merkezidir. Bu sinir ağları, verilen görevi bir araya getiren yığılmış katmanların (her katmanın bazı nöronları vardır) bir koleksiyonudur. Bu nedenle, daha fazla katmanı bir araya topladıkça, yani daha derine indikçe veya modelin derinliğini artırdıkça, performansı artırmayı dört gözle bekliyoruz.

Ancak, bu derin sinir ağları, bozulma sorunlarından rahatsız. Peki, sinir ağlarında bozulma tam olarak nedir? Bu sorunu nasıl çözeriz? Bunlar, Kalıntı Bloğun deşifre ettiği sorulardan bazılarıdır.

İki ağı ele alalım, “A” ağı: sığ bir ağ ve “B” ağı: A ağının daha derin bir karşılığı. Şimdi, daha iyi değilse, en azından B ağı ile aynı performansı elde etmek istiyoruz. Yani, verilen ağ A, kimlik eşlemesini B'yi oluşturmak için ekstra katmanlar olarak ekledik. Bu kurulum, daha derin model B'nin daha sığ olandan daha yüksek eğitim hatası üretmemesini sağlamalıdır. Ancak deneyler, bu ayarın, benzer şekilde

daha iyi veya aynı performansa sahip çözümler bulamadığını gösteriyor.

Bu, modelin optimizasyon sırasında kimlik eşlemeyi öğrenmesinin çok zor olduğunu kanıtlıyor. Bozulma sorununu çözmek için, atlamalı bağlantılar adı verilen bir kurulumumuz var. Alternatif olarak kısa yol bağlantıları olarak adlandırılır, mimarideki bazı katmanları atlar ve önceki katmanın çıktısını mevcut konuma besler, böylece optimizasyona yardımcı olur.


Yığılmış katmanların bazılarının değer eklediği, bazılarının ise sıfır olduğu bir sinir ağı düşünün. Ancak artık blok nedeniyle ağırlıkları koruyabiliyor ve sürekli olarak optimize edip daha iyi doğruluk elde edebiliyoruz. Bu uç noktaya kadar, artık $F(x)$ 'i sıfıra itmek, doğrusal olmayan katmanlardan oluşan bir kimlik eşlemesine sığdırmaktan daha kolaydır. Bağlantıları atlama, daha derin sinir ağlarının bozulmasını ortadan kaldırmak için fayda sağlamaktadır.

Artık Blok, ESA ile herhangi bir değişiklik yapılmadan kullanılabilir. ESA da yığılmış katmanların çıktısı değişir ancak yaklaşım tamamen aynıdır.

Sıralı ağlar için karayolu ağı olarak adlandırılan bir ağımız var. Otoyol ağları, ek kapıları olan kısa yol bağlantılarıdır. Bu kapılar verilere bağımlıdır ve bazı parametrelere sahiptir, oysa artık ağıdaki kısa yol bağlantısının herhangi bir parametresi yoktur. Bu kapılar bilginin geçip geçmeyeceğini belirler. Bilgi akışını düzenlemek için modüle edilmiş bir atlama bağlantısı görevi görür. Bu ağlar, bilgiyi unutmak, güncellemek ve çıktı almak için birden fazla kapıya sahip olduğumuz UKSB tipi ağlardan esinlenmiştir.

ResNet mimari olarak yayılım işlemini önemli ölçüde başarmıştır. ResNet, AR-GE kapsamında popülerlik kazanmakta ve mimarisi yoğun bir şekilde incelenmektedir. ResNet, yüzlerce hatta binlerce katmana kadar eğitmeyi mümkün kılan bir performans elde eder. Başka bir deyişle sonraki artık değer katmanlarını besleyen artık bloklardan oluşur. Oluşan bu bloklar ile ResNet genel bir model olmaktan çıkar. ResNet mimarisinin ResNet-18, ResNet-50, ResNet-101 vb. türleri bulunmaktadır (Maqsood ve ark., 2022). Bu türlerin model yapısı aynı olmasına rağmen ResNet modelinin yanındaki sayılar katman sayısını ifade etmektedir. ResNet-18 modeli 18 katmanlı bir derin evrimsel ağ yapısına sahiptir ve ResNet modellerin girdi boyutu 224×224 piksel çözünürlüktedir (Çalışkan ve ark., 2022b). Artık bloklar artık özellikle derin ağlarda kullanılan, tahmin sağlayan ve modelin performansına katkı sağlamayan katmanlardan kaçınan katmanlardan oluşmaktadır. Normal evrimsel ağlarda katmanlar arası veri ve özellik aktarımı yapılırken bir önceki katman veya bir sonraki katman ile doğrudan

iletişim sağlanır; artık blokların kullanıldığı evrişimsel ağlarda, iki veya üç katmandan sonra katmanlarla doğrudan iletişim sağlanır. Böylece model eğitilirken gereksiz görünen ağlar atlatılarak performansa katkı sağlanır. Evrişimli ağlarda derinlik ile model hızı ters orantılı ve zaman tüketimi ile de doğru orantılıdır. Ayrıca derin ağların modelde birleştirilmesi sonucunda doğruluk oranlarının düşmesine neden olabilir. Bu nedenle artık bloklar çözüm noktası olarak kullanılabilir. Artık bloklar derin ağlarda kullanımlarıyla kullanılan modelin performansını olumsuz olarak etkileyen katmanları atlayarak doğruluğa daha hızlı bir şekilde ulaşabilmektedir (Boumaraf ve ark., 2021). ResNet-X modelinin genel mimari yapısı Şekil 4.3'te gösterilmiştir.



Şekil 4.3. ResNet-X modelinin mimari yapısı

Özetlemek gerekirse; ResNet, kaybolan veya patlayan gradyan sorunlarını çözmek için tasarlanmış bir mimaridir. Bu ağ, bağlantı atlama adı verilen bir teknik kullanılıyor. Bu teknikte atlama bağlantısı, aradaki bazı katmanları atlayarak bir katmanın aktivasyonlarını diğer katmanlara bağlar ve artık bir blok oluşturmuş olur. ResNet bu artık blokları bir araya getirerek yapılır.

Çalışmamızda ResNet-18, ResNet-50 ve ResNet-101 modelleri kullanılmıştır. Bu modellerin ortak özellikleri;

- Aynı mimari yapısına sahip olması (paralel yapılı ESA modeli)
- TB katmanların aynı sayıda öznelik vermesi
- Giriş çözünürlüklerinin 224x224 olması, vs.
- Sınıflandırıcı olarak genellikle Softmax yönteminin son katmanda tercih edilmesi.

ESA modellerin genel yapısında ek bir sınıflandırma yöntemi eklenmediği sürece genellikle sınıflandırma rolünü softmax fonksiyonu üstlenir. ESA modellerinin sınıflandırma işlemini gerçekleştiren ve modellerin son katmanda yer alan aktivasyon

fonksiyonu olarak ta bilinen softmax, TB katmanlardan işlenerek elde edilen giriş değerlerini olasılık tabanlı $[0,1]$ değerlere dönüştürür. Ardından girdi verisini olasılık tabanlı değerlere göre karşılaştırarak ilgili sınıfa aktarılmasını sağlar (Çalışkan ve ark., 2022b; Gao ve ark., 2021).



5. DENEY ANALİZLER VE TARTIŞMA

Bu çalışmada, DÖ modelleri ve makine öğrenme yöntemleri için, varsayılan değerler korunarak eğitimler gerçekleştirildi. Eğitimlerin gerçekleşmesinde kullanılan donanımlar ve bilgileri şu şekilde özetleyebiliriz; Intel® Xeon® CPU @3.20 GHz CPU, 8 GB RAM ve 4 GB GPU destekli Nvidia Geforce ekran kartı kullanıldı. Yazılımda derlenen ResNet-18, ResNet-50 ve ResNet-101 modelleri için tercih edilmiş parametreler Çizelge 5.1’de gösterilmiştir (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b).

Çizelge 5.1. ResNet modellerinin eğitimi sürecinde tercih edilmiş parametre değerleri

Parametre	Tercih / Değer
İterasyon sayısı	420
Dönem/Devir sayısı	4
Öğrenme oranı	0,0001
Optimizasyon	SGD
Donanım kaynağı	Tekli GPU
Mini – topluluk (mini-batch)	16
Eğitim oranı: test oranı	0.7:0.3

Karmaşıklık matrisi, bu çalışmanın deneysel analizlerinde ölçüt olarak belirlenmiştir ve ölçütte kullanılan metrikler; doğruluk, kesinlik, f1-skor, geri çağırma şeklindedir. Bu metriklerin hesaplanmasında Denklem 4-7’deki matematiksel formüller kullanıldı. Denklem 4-7’de kullanılan kısaltmalar; doğru (D), yanlış (Y), negatif (N), pozitif (P) anlamına gelir (Çalışkan ve ark., 2022a; Çalışkan ve ark., 2022b).

$$\text{Geri çağırma} = DP / (DP + YN) \quad (4)$$


$$\text{Kesinlik} = DP / (DP + YP) \quad (5)$$

$$F\text{-skor} = 2 \times DP / (2 \times DP + DN + YP + YN) \quad (6)$$


$$\text{Doğruluk} = (DP + DN) / (DP + DN + YP + YN) \quad (7)$$

Bu çalışmada üç deney gerçekleştirildi. Birinci deney analizinde, veri kümesi ResNet-18, ResNet-50 ve ResNet-101 modelleriyle eğitildi. Eğitim sürecinde sınıflandırma işlemi için softmax yöntemi kullanıldı ve softmax’a girdi verisi olarak her bir modelin TB_{1000} katmanından elde edilmiş 1000 özellik verildi. Bu deneyde modellerden elde edilmiş eğitim başarı grafikleri Şekil 5.1’de ve karmaşıklık matrisleri

Şekil 5.2’de gösterilmiştir. İlk olarak hazırlanan deneyin analiz sonuçları Çizelge 5.2’de verilmiştir.



Şekil 5.1. ResNet modellerinin 1000 özellikli eğitim ve test başarı grafikleri;
a) ResNet-18, b) ResNet-50, c) ResNet-101




Şekil 5.2. ResNet modellerinden elde edilmiş 1000 özellikli karmaşıklık matrisleri;
a) ResNet-18, b) ResNet-50, c) ResNet-101

Çizelge 5.2 incelendiğinde, ResNet-18 model ile %98.23, ResNet-50 model ile %97.83 ve ResNet-101 model ile %99.02 genel doğruluk başarısı elde edilmiştir. En iyi performansı modeller arasında ResNet-101 vermiştir. Üç modelinde sınıflandırma sürecinde softmax yöntemi kullanıldı ve bu modellerin TB son katmanından elde edilmiş 1000 özellik seti softmax yöntemine girdi olarak verildi.

Çizelge 5.2. ResNet modellerinden elde edilmiş karmaşıklık matrislerin (1000 özellikli) metrik sonuçları

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)
ResNet-18	İyi huylu	0,96	0,98	0,97	98,23
	Kötü huylu	0,99	0,98	0,99	
ResNet-50	İyi huylu	0,93	1,0	0,97	97,83
	Kötü huylu	1,0	0,97	0,98	
ResNet-101	İyi huylu	0,99	0,98	0,98	99,02
	Kötü huylu	0,99	0,99	0,99	

İkinci deneyde ResNet modellerin son katmanına yeni TB katman eklendi ve tür sayısı kadar çıkış veren özellik setleri elde edildi. Modeller eğitilerek TB_2 katmanından elde edilen ($2 \times \text{girdi sayısı}$) boyutundaki özellik setleri softmax yöntemi ile yeniden sınıflandırıldı. Bu deneyde modellerden elde edilmiş karmaşıklık matrisleri Şekil 5.3'te gösterilmiştir. İkinci olarak hazırlanan deneyin çıktıları Çizelge 5.3'te verilmiştir. Çizelge 5.3 incelendiğinde, ResNet-18 model ile %98.62, ResNet-50 model ile %98.43 ve ResNet-101 model ile %98.62 genel doğruluk başarısı elde edilmiştir. Üç modelinde sınıflandırma sürecinde softmax yöntemi kullanıldı ve bu modellerden TB, son katmanından elde edilmiş 2 özellik seti softmax yöntemine girdi olarak verildi. Çizelge 5.2 ve Çizelge 5.3 analizleri karşılaştırıldığında tür tabanlı tam bağlantılı katmanın (TB_2) performans anlamında TB_{1000} katmanı ile yakın performans gösterdiği gözlemlenmiştir.

**Şekil 5.3.** ResNet modellerinden elde edilmiş 2 özellikli karmaşıklık matrisleri;


a) ResNet-18, b) ResNet-50, c) ResNet-101

Çizelge 5.2. ResNet modellerinden elde edilmiş karmaşıklık matrislerin (2 özellikli) metrik sonuçları

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)
ResNet-18	İyi huylu	0,98	0,98	0,98	98,62
	Kötü huylu	0,99	0,99	0,99	
ResNet-50	İyi huylu	0,97	0,98	0,98	98,43
	Kötü huylu	0,99	0,99	0,99	
ResNet-101	İyi huylu	0,98	0,98	0,98	98,62
	Kötü huylu	0,99	0,99	0,99	

Üçüncü deneyde önerilen yaklaşım veri kümesine uygulandı. Üç modelden elde edilmiş FC_2 katmanları birleştirilerek ($3 \times FC_2$) sırasıyla softmax, DVM, EYK ve LDA yöntemleri ile sınıflandırıldı. Sınıflandırma sürecinde softmax ve makine öğrenme yöntemlerinden %100 genel doğruluk başarısı elde edildi. Önerilen yaklaşımla elde edilmiş karmaşıklık matrisi ve ROC eğrisi Şekil 5.4'te gösterilmiştir. Üçüncü olarak hazırlanan deneyin mertik çıktıları Çizelge 5.3'te verilmiştir.

Deneysel analizler, önerilen yaklaşımın meme kanseri türlerini başarılı bir şekilde ayırt ettiğini göstermiştir. Bu çalışmada önerilen yaklaşımın her bir adımı deneylerde (deney 1, deney 2, deney 3) uygulanarak, tür tabanlı TB katmanının performanslarına katkı sağladığı görüldü. Ayrıca özellik setlerinin birleştirilmesi ile %100'lük genel doğruluk başarısı sınıflandırma yöntemleriyle elde edildi.




Şekil 5.4. Önerilen yaklaşımda, softmax ve makine öğrenme yöntemleri ile gerçekleştirilmiş analiz sonuçları;

a) Karmaşıklık matrisi, b) ROC eğrisi

Çizelge 5.3. Önerilen yaklaşımın analiz sonuçları

ESA model	Sınıf	Kesinlik	Geri çağırma	F1-skor	Doğruluk (%)
Önerilen yaklaşım	İyi huylu	1,0	1,0	1,0	100
	Kötü huylu	1,0	1,0	1,0	


Şekil 5.5. ResNet modellerinin 1000 özellikli eğitim-test kayıp grafikleri;
a) ResNet-18, b) ResNet-50, c) ResNet-101

1.1 ☆ Tree	Accuracy: 99.0%
Last change: Fine Tree	6/6 features
1.2 ☆ Tree	Accuracy: 99.0%
Last change: Medium Tree	6/6 features
1.3 ☆ Tree	Accuracy: 99.0%
Last change: Coarse Tree	6/6 features
1.4 ☆ Linear Discriminant	Accuracy: 100.0%
Last change: Linear Discriminant	6/6 features
1.5 ☆ Quadratic Discriminant	Accuracy: 100.0%
Last change: Quadratic Discriminant	6/6 features
1.6 ☆ Logistic Regression	Accuracy: 100.0%
Last change: Logistic Regression	6/6 features
1.7 ☆ Naive Bayes	Accuracy: 100.0%
Last change: Gaussian Naive Bayes	6/6 features
1.8 ☆ Naive Bayes	Accuracy: 100.0%
Last change: Kernel Naive Bayes	6/6 features


Şekil 5.6. Makine Öğrenme Yöntemleri Sonuçları-1

1.10	☆	SVM	Accuracy: 100.0%
Last change: Quadratic SVM			6/6 features
1.11	☆	SVM	Accuracy: 100.0%
Last change: Cubic SVM			6/6 features
1.12	☆	SVM	Accuracy: 98.4%
Last change: Fine Gaussian SVM			6/6 features
1.13	☆	SVM	Accuracy: 100.0%
Last change: Medium Gaussian SVM			6/6 features
1.14	☆	SVM	Accuracy: 100.0%
Last change: Coarse Gaussian SVM			6/6 features
1.15	☆	KNN	Accuracy: 100.0%
Last change: Fine KNN			6/6 features
1.16	☆	KNN	Accuracy: 100.0%
Last change: Medium KNN			6/6 features
1.17	☆	KNN	Accuracy: 100.0%
Last change: Coarse KNN			6/6 features
1.18	☆	KNN	Accuracy: 99.4%


Şekil 5.7. Makine Öğrenme Yöntemleri Sonuçları-2



Şekil 5.8. Makine Öğrenme Yöntemleri Sonuçları-3



Şekil 5.9. EYK çıktısı



Şekil 5.10. ROC eğrisi

6. SONUÇLAR VE ÖNERİLER

Dünyada birçok ülkenin sağlık sistemleri alanında karşılaştığı en önemli sorun, hastalıkların tanısıdır. Bu çalışmanın konusu olan meme kanseri de dünya genelinde kadınlar arasında yoğun bir şekilde rastlanan ve ölümcül sonuçlara neden olan bir hastalık türüdür. Kanser hastalığının yapısal olarak oluşmasına sebep olan tümör, iyi ve kötü huylu olmak üzere iki sınıfta incelenmektedir. Bu hastalığın erken tanısı hastalığın sağ kalım oranını ciddi oranda arttırmaktadır. Bu sebeplerden dolayı erken tanı üzerine kurgulanan birçok çalışma yapılmaktadır. Son zamanlarda yapılan çalışmalarda YZ tabanlı yaklaşımlar da yer almaktadır. YZ'nin tıp alanında yaygınlaşmasıyla uzman hekimlerin hastalık teşhisindeki ihtiyacını da ciddi oranda azaltmaktadır.

Bu çalışmada, meme kanserine neden olabilecek iyi huylu ve kötü huylu tümörlerin sınıflandırılması gerçekleştirilerek önerilen yaklaşım da, DÖ modelleriyle makine öğrenme yöntemlerini bir araya getiren yeni bir karar destek sistemi sunulmuştur. Çalışmada, DÖ modellerini eğitmek için ihtiyaç duyulan veri setlerinin olduğu durumda, önerilen yaklaşımların tıp alanında karar verme süreçlerine büyük oranda destek sağlayacağı düşünülmektedir. Erken tanı, bu hastalığın sağ kalım oranını artırmaktadır.

Tür tabanlı yeni bir TB katmanının ESA modellerinin son katmanına entegre edilmesi ile modellerin performansına katkı sağladığını göstermiştir. Sınıflandırma süreci tek bir yöntemden destek alınmamış, DVM, EYK ve LDA yöntemleriyle de sınıflandırma süreci geliştirilmiştir. Bu yöntemler ile sınıflandırma başarısını büyük oranda desteklemiş ve çalışmanın başarısını sağlamlaştırmış, ancak önerilen modelin maliyetini de arttırmıştır. Son olarak önerilen yaklaşım da tür tabanlı TB katmanlarından elde edilmiş özniteliklerin birleştirilmesi, sınıflandırma başarısını artırmıştır. Sonuç olarak bu çalışmanın deneysel analizde %100 genel doğruluk başarısı elde edilmiştir.

Gelecek çalışmada farklı görüntüleme yöntemiyle elde edilmiş veri setleri kullanılarak meme kanserinin tanı sürecinde DÖ tabanlı yeni yaklaşımlar tasarlanacaktır. Veri kümelerine ön işlem adımları eklenerek girdi görüntüsünden daha verimli yararlanılacaktır. Ayrıca öznitelik seçiminde daha verimli özelliklerin ön plana çıkartılabilmesi için meta-sezgisel yöntemler de önerilen yaklaşıma ilave edilecektir. Çalışmada sunulan başarı oranının önerilen yöntemlerin geliştirilmesiyle nasıl kullanacağı üzerine daha ileri araştırmaların önünü açacaktır.

7. KAYNAKLAR

- Abdullah, D. M., & Abdulazeez, A. M., 2021, Machine Learning Applications based on SVM Classification A Review, *Qubahan Academic Journal*, 1(2), 81-90.
- Abunasser, B. S., AL-Hiealy, M. R. J., Zaqout, I. S., & Abu-Naser, S. S., 2022, Breast cancer detection and classification using deep learning Xception algorithm, *International Journal of Advanced Computer Science and Applications*, 13(7).
- Adem, K., 2020, Diagnosis of breast cancer with Stacked autoencoder and Subspace kNN, *Physica A: Statistical Mechanics and its Applications*, 551, 124591.
- Aggarwal, K., Mijwil, M. M., Al-Mistarehi, A. H., Alomari, S., Gök, M., Alaabdin, A. M. Z., & Abdulrhman, S. H., 2022, Has the Future Started? The Current Growth of Artificial Intelligence, Machine Learning, and Deep Learning, *Iraqi Journal for Computer Science and Mathematics*, 3(1), 115-123.
- Agnes, S. A., Anitha, J., Pandian, S. I. A., & Peter, J. D., 2020, Classification of mammogram images using multiscale all convolutional neural network (MA-CNN), *Journal of medical systems*, 44, 1-9.
- Ahmad, L. G., Eshlaghy, A. T., Poorebrahimi, A., Ebrahimi, M., & Razavi, A. R., 2013, Using three machine learning techniques for predicting breast cancer recurrence, *J Health Med Inform*, 4(124), 3.
- Ahmed, L., Iqbal, M. M., Aldabbas, H., Khalid, S., Saleem, Y., & Saeed, S., 2020, Images data practices for semantic segmentation of breast cancer using deep neural network, *Journal of Ambient Intelligence and Humanized Computing*, 1-17.
- Ajit, A., Acharya, K., & Samanta, A., 2020, A review of convolutional neural networks, *In 2020 international conference on emerging trends in information technology and engineering (ic-ETITE)*, IEEE, 1-5.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S., 2017, Understanding of a convolutional neural network, *In 2017 international conference on engineering and technology (ICET)*, IEEE, 1-6.
- Alfian, G., Syafrudin, M., Fahrurrozi, I., Fitriyani, N. L., Atmaji, F. T. D., Widodo, T., & Rhee, J., 2022, Predicting breast cancer from risk factors using SVM and extra-trees-based feature selection method, *Computers*, 11(9), 136.
- Alhadidi, B., Zu'bi, M. H., & Suleiman, H. N., 2007, Mammogram breast cancer image detection using image processing functions, *Information Technology Journal*, 6(2), 217-221.
- Ali, M. S., Miah, M. S., Haque, J., Rahman, M. M., & Islam, M. K., 2021, An enhanced technique of skin cancer classification using deep convolutional neural network with transfer learning models, *Machine Learning with Applications*, 5, 100036.
- Aljuaid, H., Alturki, N., Alsubaie, N., Cavallaro, L., & Liotta, A., 2022, Computer-

- aided diagnosis for breast cancer classification using deep neural networks and transfer learning, *Computer Methods and Programs in Biomedicine*, 223, 106951.
- Allain, J. S., 2012, From Jeopardy to Jaundice: The medical liability implications of Dr. Watson and other artificial intelligence systems, *La. L. Rev.*, 73, 1049.
- Alsaggaf, W., Cömert, Z., Nour, M., Polat, K., Brdese, H., & Toğaçar, M., 2020, Predicting fetal hypoxia using common spatial pattern and machine learning from cardiotocography signals, *Applied Acoustics*, 167, 107429.
- Alzubaidi, L., Al-Shamma, O., Fadhel, M. A., Farhan, L., Zhang, J., & Duan, Y., 2020, Optimizing the performance of breast cancer classification by employing the same domain transfer learning from hybrid deep convolutional neural network model, *Electronics*, 9(3), 445.
- Arora, D., Garg, M., & Gupta, M., 2020, Diving deep in deep convolutional neural network, In 2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN), IEEE, 749-751.
- Asri, H., Mousannif, H., Al Moatassime, H., & Noel, T., 2016, Using machine learning algorithms for breast cancer risk prediction and diagnosis, *Procedia Computer Science*, 83, 1064-1069.
- Assegie, T. A., 2021, An optimized K-Nearest Neighbor based breast cancer detection, *Journal of Robotics and Control (JRC)*, 2(3), 115-118.
- Altameem, A., Mahanty, C., Poonia, R. C., Saudagar, A. K. J., & Kumar, R., 2022, Breast cancer detection in mammography images using deep convolutional neural networks and fuzzy ensemble modeling techniques, *Diagnostics*, 12(8), 1812.
- Ayana, G., Ryu, J., & Choe, S. W., 2022, Ultrasound-Responsive Nanocarriers for Breast Cancer Chemotherapy, *Micromachines*, 13(9), 1508.
- Başaran, E., 2020, Timpanik Membran Görüntü Analizi ve Yapay Zeka Kullanılarak Sanal Otitis Media Tanı Sisteminin Geliştirilmesi, *PhD Thesis*.
- Başaran, E., 2022, A new brain tumor diagnostic model: Selection of textural feature extraction algorithms and convolution neural network features with optimization algorithms, *Computers in Biology and Medicine*, 148, 105857.
- Başaran, E., Cömert, Z., & Çelik, Y., 2022, Neighbourhood component analysis and deep feature-based diagnosis model for middle ear otoscope images, *Neural Computing and Applications*, 34(8), 6027-6038.
- Beck, A., & Sharon, R., 2022, New results on multi-dimensional linear discriminant analysis, *Operations Research Letters*, 50(1), 1-7.
- Beharee, N., Shi, Z., Wu, D., & Wang, J., 2019, Diagnosis and treatment of cervical cancer in pregnant women, *Cancer medicine*, 8(12), 5425-5430.

- Bektaş, B., & Babur, S., 2016, Machine learning based performance development for diagnosis of breast cancer, In *2016 Medical Technologies National Congress (TIPTEKNO)*, IEEE, 1-4.
- Benmeziane, H., Maghraoui, K. E., Ouarnoughi, H., Niar, S., Wistuba, M., & Wang, N., 2021, A comprehensive survey on hardware-aware neural architecture search, arXiv preprint arXiv:2101.09336.
- Botlagunta, M., Botlagunta, M. D., Myneni, M. B., Lakshmi, D., Nayyar, A., Gullapalli, J. S., & Shah, M. A., 2023, Classification and diagnostic prediction of breast cancer metastasis on clinical data using machine learning algorithms, *Scientific Reports*, 13(1), 485.
- Boumaraf, S., Liu, X., Zheng, Z., Ma, X., & Ferkous, C., 2021, A new transfer learning based approach to magnification dependent and independent classification of breast cancer in histopathological images, *Biomedical Signal Processing and Control*, 63, 102192.
- Brunette, E. S., Flemmer, R. C., & Flemmer, C. L., 2009, A review of artificial intelligence, In *2009 4th International Conference on Autonomous Robots and Agents*, Ieee, 385-392.
- Canhoto, A. I., & Clear, F., 2020, Artificial intelligence and machine learning as business tools: A framework for diagnosing value destruction potential, *Business Horizons*, 63(2), 183-193.
- Carter, S. M., Rogers, W., Win, K. T., Frazer, H., Richards, B., & Houssami, N., 2020, The ethical, legal and social implications of using artificial intelligence systems in breast cancer care, *The Breast*, 49, 25-32.
- Chapala, H., & Sujatha, B., 2020, ResNet: detection of invasive ductal carcinoma in breast histopathology images using deep learning, In *2020 International Conference on Electronics and Sustainable Communication Systems (ICESC)*, IEEE, 60-67.
- Chen, J., You, H., & Li, K., 2020, A review of thyroid gland segmentation and thyroid nodule segmentation methods for medical ultrasound images, *Computer methods and programs in biomedicine*, 185, 105329.
- Chen, J., Wan, Z., Zhang, J., Li, W., Chen, Y., Li, Y., & Duan, Y., 2021, Medical image segmentation and reconstruction of prostate tumor based on 3D AlexNet, *Computer methods and programs in biomedicine*, 200, 105878.
- Cherif, W., 2018, Optimization of K-NN algorithm by clustering and reliability coefficients: application to breast-cancer diagnosis, *Procedia Computer Science*, 127, 293-299.
- Coelho, I. M., Coelho, V. N., Luz, E. J. D. S., Ochi, L. S., Guimarães, F. G., & Rios, E., 2017, A GPU deep learning metaheuristic based model for time series forecasting. *Applied Energy*, 201, 412-418.

- Çalışkan, A., 2022, Classification of Tympanic Membrane Images based on VGG16 Model, *Kocaeli Journal of Science and Engineering*, 5(1), 105-111.
- Çalışkan, A., 2023a, Detecting human activity types from 3D posture data using deep learning models, *Biomedical Signal Processing and Control*, 81, 104479.
- Çalışkan, A., 2023b, Diagnosis of malaria disease by integrating chi-square feature selection algorithm with convolutional neural networks and autoencoder network, *Transactions of the Institute of Measurement and Control*, 45(5), 975-985.
- Çalışkan, A., Ateş, F.F., & Toğaçar, M., 2022a, Ultrason Tabanlı Meme Kanseri Görüntülerinin Derin Öğrenme Yaklaşımları ile Sınıflandırılması, *Fırat Üniversitesi Fen Bilimleri Dergisi*, 34(2), 179-187.
- Çalışkan, A., Ateş, F.F., & Toğaçar, M., 2022b, Meme Kanserinin Tespiti için Yapay Zekâ Tabanlı Hibrit Bir Model Önerisi, *Fırat Üniversitesi Fen Bilimleri Dergisi*, 34(2), 131-141.
- Çalışır, D., & Doğantekin, E., 2011, An automatic diabetes diagnosis system based on LDA-wavelet support vector machine classifier, *Expert Systems with Applications*, 38(7), 8311-8315.
- Dammu, H., Ren, T., & Duong, T. Q., 2023, Deep learning prediction of pathological complete response, residual cancer burden, and progression-free survival in breast cancer patients, *Plos one*, 18(1), e0280148.
- Dar, R. A., Rasool, M., & Assad, A., 2022, Breast cancer detection using deep learning: Datasets, methods, and challenges ahead, *Computers in Biology and Medicine*, 106073.
- Dargan, S., Kumar, M., Ayyagari, M. R., & Kumar, G., 2020, A survey of deep learning and its applications: a new paradigm to machine learning, *Archives of Computational Methods in Engineering*, 27(4), 1071-1092.
- Das, S., Dey, A., Pal, A., & Roy, N., 2015, Applications of artificial intelligence in machine learning: review and prospect, *International Journal of Computer Applications*, 115(9).
- Debelee, T. G., Schwenker, F., Ibenthal, A., & Yohannes, D., 2020, Survey of deep learning in breast cancer image analysis, *Evolving Systems*, 11(1), 143-163.
- Dempsey, P. J., 2004, The history of breast ultrasound. *Journal of ultrasound in medicine*, 23(7), 887-894.
- Desai, M., & Shah, M., 2021, An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN), *Clinical eHealth*, 4, 1-11.
- Dey, M., Mondal, A., Mahata, S. K., & Sarkar, D., 2022, Breast Cancer Classification Using Deep Convolutional Neural Networks, *In Proceedings of International Conference on Computational Intelligence, Data Science and Cloud Computing: IEM-ICDC 2021*, 179-187.

- Dhaka, V. S., Meena, S. V., Rani, G., Sinwar, D., Ijaz, M. F., & Woźniak, M., 2021, A survey of deep convolutional neural networks applied for prediction of plant leaf diseases, *Sensors*, 21(14), 4749.
- Dhillon, A., & Verma, G. K., 2020, Convolutional neural network: a review of models, methodologies and applications to object detection, *Progress in Artificial Intelligence*, 9(2), 85-112.
- Dogantekin, E., Dogantekin, A., Avci, D., & Avci, L., 2010, An intelligent diagnosis system for diabetes on linear discriminant analysis and adaptive network based fuzzy inference system: LDA-ANFIS, *Digital Signal Processing*, 20(4), 1248-1255.
- Doğan, B., Demir, Ö., & Çalık, S. K., 2016, Computer-aided detection of brain tumors using morphological reconstruction, *Uludağ University Journal of The Faculty of Engineering*, 21(2), 257-268.
- Dominique, C., Callonnec, F., Berghian, A., Defta, D., Vera, P., Modzelewski, R., & Decazes, P., 2022, Deep learning analysis of contrast-enhanced spectral mammography to determine histoprognotic factors of malignant breast tumours, *European radiology*, 1-11.
- Dong, S., Wang, P., & Abbas, K., 2021, A survey on deep learning and its applications, *Computer Science Review*, 40, 100379.
- Ebert, C., & Louridas, P., 2016, Machine learning, *IEEE Software*, 33(5), 110-115.
- Egwom, O. J., Hassan, M., Tanimu, J. J., Hamada, M., & Ogar, O. M., 2022, An LDA–SVM Machine Learning Model for Breast Cancer Classification, *BioMedInformatics*, 2(3), 345-358.
- Emmert-Streib, F., Yang, Z., Feng, H., Tripathi, S., & Dehmer, M., 2020, An introductory review of deep learning for prediction models with big data, *Frontiers in Artificial Intelligence*, 3, 4.
- Erwandi, R., & Suyanto, S., 2020, Improved Residual Neural Network for Breast Cancer Classification, In *2020 3rd International Conference on Information and Communications Technology (ICOIACT)*, IEEE, 362-366.
- Eskreis-Winkler, S., Onishi, N., Pinker, K., Reiner, J. S., Kaplan, J., Morris, E. A., & Sutton, E. J., 2021, Using deep learning to improve nonsystematic viewing of breast cancer on MRI, *Journal of Breast Imaging*, 3(2), 201-207.
- Eyupoglu, C., 2018, Breast cancer classification using k-nearest neighbors algorithm, *The Online Journal of Science and Technology*, 8(3), 29-34.
- Fatima, N., Liu, L., Hong, S., & Ahmed, H., 2020, Prediction of breast cancer, comparative review of machine learning techniques, and their analysis, *IEEE Access*, 8, 150360-150376.
- Ferreira, C. A., Melo, T., Sousa, P., Meyer, M. I., Shakibapour, E., Costa, P., & Campilho, A., 2018, Classification of breast cancer histology images through

- transfer learning using a pre-trained inception resnet v2, *In Image Analysis and Recognition: 15th International Conference*, Springer International Publishing, 763-770.
- Ferro, S., Bottigliengo, D., Gregori, D., Fabricio, A. S., Gion, M., & Baldi, I., 2021, Phenomapping of patients with primary breast cancer using machine learning-based unsupervised cluster analysis, *Journal of personalized medicine*, 11(4), 272.
- Freeman, K., Geppert, J., Stinton, C., Todkill, D., Johnson, S., Clarke, A., & Taylor-Phillips, S., 2021, Use of artificial intelligence for image analysis in breast cancer screening programmes: systematic review of test accuracy, *bmj*, 374.
- Gambella, C., Ghaddar, B., & Naoum-Sawaya, J., 2021, Optimization problems for machine learning: A survey, *European Journal of Operational Research*, 290(3), 807-828.
- Ganggayah, M. D., Taib, N. A., Har, Y. C., Lio, P., & Dhillon, S. K., 2019, Predicting factors for survival of breast cancer patients using machine learning techniques, *BMC medical informatics and decision making*, 19(1), 1-17.
- Gao, Y., Reig, B., Heacock, L., Bennett, D. L., Heller, S. L., & Moy, L., 2021, Magnetic resonance imaging in screening of breast cancer, *Radiologic Clinics*, 59(1), 85-98.
- Guo, C., Wang, J., Wang, Y., Qu, X., Shi, Z., Meng, Y., & Hua, K., 2021, Novel artificial intelligence machine learning approaches to precisely predict survival and site-specific recurrence in cervical cancer: a multi-institutional study, *Translational Oncology*, 14(5), 101032.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S., 2016, Deep learning for visual understanding: A review, *Neurocomputing*, 187, 27-48.
- Günther, U. L., Ludwig, C., & Rüterjans, H., 2000, NMRLAB—advanced NMR data processing in Matlab, *Journal of Magnetic Resonance*, 145(2), 201-208.
- Hamed, G., Marey, M. A. E. R., Amin, S. E. S., & Tolba, M. F. (2020). Deep learning in breast cancer detection and classification. *In The International Conference on Artificial Intelligence and Computer Vision*, Springer, Cham, 322-333.
- Hamet, P., & Tremblay, J., 2017, Artificial intelligence in medicine, *Metabolism*, 69, 36-40.
- Harefa, J., Alexander, A., & Pratiwi, M., 2017, Comparison classifier: support vector machine (SVM) and K-nearest neighbor (K-NN) in digital mammogram images, *Jurnal Informatika dan Sistem Informasi*, 2(2), 35-40.
- Haria, P., Thakur, M. H., Popat, P., Katdare, A., & Chauhan, S., 2022, Breast Imaging: Past and Present, *Indian Journal of Medical and Paediatric Oncology*, 43(01), 109-113.
- Hinton, G. E., & Salakhutdinov, R. R., 2006, Reducing the dimensionality of data with

- neural networks, *science*, 313(5786), 504-507.
- Hofvind, S., Holen, Å., Aas, T., Roman, M., Sebuødegård, S., & Akslen, L. A., 2015, Women treated with breast conserving surgery do better than those with mastectomy independent of detection mode, prognostic and predictive tumor characteristics, *European Journal of Surgical Oncology (EJSO)*, 41(10), 1417-1422.
- Houssein, E. H., Emam, M. M., Ali, A. A., & Suganthan, P. N., 2021, Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review, *Expert Systems with Applications*, 167, 114161.
- Huang, M. W., Chen, C. W., Lin, W. C., Ke, S. W., & Tsai, C. F., 2017, SVM and SVM ensembles in breast cancer prediction, *PloS one*, 12(1), e0161501.
- Huang, P., 2020, An integrated approach to ultrasound imaging in medicine and biology, *BIO Integration*, 1(3), 105-109.
- Huang, S., Cai, N., Pacheco, P. P., Narrandes, S., Wang, Y., & Xu, W., 2018, Applications of support vector machine (SVM) learning in cancer genomics, *Cancer genomics & proteomics*, 15(1), 41-51.
- Ibrokhimov, B., & Kang, J. Y., 2022, Two-Stage Deep Learning Method for Breast Cancer Detection Using High-Resolution Mammogram Images, *Applied Sciences*, 12(9), 4616.
- Iseri, I., & Oz, C., 2014, Computer aided detection of microcalcification clusters in mammogram images with machine learning approach, *Optoelectronics and Advanced Materials*, 8, 689-695.
- Islam, M. M., Haque, M. R., Iqbal, H., Hasan, M. M., Hasan, M., & Kabir, M. N., 2020, Breast cancer prediction: a comparative study using machine learning techniques, *SN Computer Science*, 1, 1-14.
- Istrail, S., & Marcus, S., 2012, Alan turing and john von neumann-their brains and their computers, *In International Conference on Membrane Computing*, Springer, Berlin, Heidelberg, 26-35.
- Jannesari, M., Habibzadeh, M., Aboulkheyr, H., Khosravi, P., Elemento, O., Totonchi, M., & Hajirasouliha, I. (2018, December). Breast cancer histopathological image classification: a deep learning approach. In 2018 IEEE international conference on bioinformatics and biomedicine (BIBM) (pp. 2405-2412). IEEE.
- Jiménez-Gaona, Y., Rodríguez-Álvarez, M. J., & Lakshminarayanan, V., 2020, Deep-learning-based computer-aided systems for breast cancer imaging: a critical review, *Applied Sciences*, 10(22), 8298.
- Jin, B., Cruz, L., & Gonçalves, N., 2020, Deep facial diagnosis: deep transfer learning from face recognition to facial diagnosis, *IEEE Access*, 8, 123649-123661.
- Kadam, V. J., Jadhav, S. M., & Vijayakumar, K., 2019, Breast cancer diagnosis using feature ensemble learning based on stacked sparse autoencoders and softmax

- regression, *Journal of medical systems*, 43(8), 1-11.
- Kakileti, S. T., & Manjunath, G., 2020, AIM for Breast Thermography, *Artificial Intelligence in Medicine*, 1-16.
- Kakria, P., Tripathi, N. K., & Kitipawang, P., 2015, A real-time health monitoring system for remote cardiac patients using smartphone and wearable sensors, *International journal of telemedicine and applications*, 2015.
- Kamilaris, A., & Prenafeta-Boldú, F. X., 2018, Deep learning in agriculture: A survey, *Computers and electronics in agriculture*, 147, 70-90.
- Karkra, S., Singh, P., Kaur, K., & Sharma, R., 2021, Deep learning architectures: a hierarchy in convolution neural network Technologies, *In Advances in Electromechanical Technologies: Select Proceedings of TEMT 2019*, Springer Singapore, 439-457.
- Kaur, M., & Mohta, A., 2019, A review of deep learning with recurrent neural network, *In 2019 International Conference on Smart Systems and Inventive Technology (ICSSIT)*, IEEE, 460-465.
- Khamparia, A., Bharati, S., Podder, P., Gupta, D., Khanna, A., Phung, T. K., & Thanh, D. N., 2021, Diagnosis of breast cancer based on modern mammography using hybrid transfer learning, *Multidimensional systems and signal processing*, 32(2), 747-765.
- Khan, S., Huh, J., & Ye, J. C., 2020, Adaptive and compressive beamforming using deep learning for medical ultrasound, *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 67(8), 1558-1572.
- Khan, S., Islam, N., Jan, Z., Din, I. U., & Rodrigues, J. J. C., 2019, A novel deep learning based framework for the detection and classification of breast cancer using transfer learning, *Pattern Recognition Letters*, 125, 1-6.
- Kobbelt, L., 1997, Stable evaluation of box-splines, *Numerical Algorithms*, 14(4), 377-382.
- Koh, J., Yoon, Y., Kim, S., Han, K., & Kim, E. K., 2022, Deep learning for the detection of breast cancers on chest computed tomography, *Clinical Breast Cancer*, 22(1), 26-31.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E., 2017, Imagenet classification with deep convolutional neural networks, *Communications of the ACM*, 60(6), 84-90.
- Kuhl, C. K., 2000, MRI of breast tumors, *European radiology*, 10(1), 46-58.
- Kuusisto, F., Costa, V. S., Nassif, H., Burnside, E., Page, D., & Shavlik, J., 2014, Support vector machines for differential prediction, *In Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, 50-65.
- Lattie, E. G., Bass, M., Garcia, S. F., Phillips, S. M., Moreno, P. I., Flores, A. M., &

- Yanez, B., 2020, Optimizing health information technologies for symptom management in cancer patients and survivors: usability evaluation, *JMIR formative research*, 4(9), e18412.
- Leite, M. L., de Loiola Costa, L. S., Cunha, V. A., Kreniski, V., de Oliveira Braga Filho, M., da Cunha, N. B., & Costa, F. F., 2021, Artificial intelligence and the future of life sciences, *Drug Discovery Today*, 26(11), 2515-2526.
- Li, D. J., Shi, J., Jin, J., Du, N. Y., & He, Y. T., 2021, Epidemiological trend of cervical cancer, *Zhonghua zhong liu za zhi* [Chinese journal of oncology], 43(9), 912-916.
- Liermann, V., 2021, Overview Machine Learning and Deep Learning Frameworks, *In The Digital Journey of Banking and Insurance*, Palgrave Macmillan, Cham, volume III, 187-224.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., & Sánchez, C. I., 2017, A survey on deep learning in medical image analysis, *Medical image analysis*, 42, 60-88.
- Liu, H. X., Zhang, R. S., Luan, F., Yao, X. J., Liu, M. C., Hu, Z. D., & Fan, B. T., 2003, Diagnosing breast cancer based on support vector machines, *Journal of Chemical Information and Computer Sciences*, 43(3), 900-907.
- Liu, H., & Lang, B., 2019, Machine learning and deep learning methods for intrusion detection systems: A survey, *applied sciences*, 9(20), 4396.
- Liu, J., Lei, J., Ou, Y., Zhao, Y., Tuo, X., Zhang, B., & Shen, M., 2022, Mammography diagnosis of breast cancer screening through machine learning: A systematic review and meta-analysis, *Clinical and Experimental Medicine*, 1-16.
- Liu, S., Wang, Y., Yang, X., Lei, B., Liu, L., Li, S. X., & Wang, T., 2019, Deep learning in medical ultrasound analysis: a review, *Engineering*, 5(2), 261-275.
- Liu, Z., Chen, H., Ren, Z., Tang, J., Xu, Z., Chen, Y., & Liu, X., 2021, Deep learning audio magnetotellurics inversion using residual-based deep convolution neural network, *Journal of Applied Geophysics*, 188, 104309.
- Loizidou, K., Skouroumouni, G., Nikolaou, C., & Pitris, C., 2022, Automatic breast mass segmentation and classification using subtraction of temporally sequential digital mammograms, *IEEE Journal of Translational Engineering in Health and Medicine*, 10, 1-11.
- Lu, S., Wang, S. H., & Zhang, Y. D., 2021, Detection of abnormal brain in MRI via improved AlexNet and ELM optimized by chaotic bat algorithm, *Neural Computing and Applications*, 33, 10799-10811.
- Luque, A., Carrasco, A., Martín, A., & de Las Heras, A., 2019, The impact of class imbalance in classification performance metrics based on the binary confusion matrix, *Pattern Recognition*, 91, 216-231.
- Ma, D., Shang, L., Tang, J., Bao, Y., Fu, J., & Yin, J., 2021, Classifying breast cancer tissue by Raman spectroscopy with one-dimensional convolutional neural

- network, *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 256, 119732.
- Madani, M., Behzadi, M. M., & Nabavi, S., 2022, The role of deep learning in advancing breast cancer detection using different imaging modalities: A systematic review, *Cancers*, 14(21), 5334.
- Mahmood, T., Li, J., Pei, Y., Akhtar, F., Imran, A., & Rehman, K. U., 2020, A brief survey on breast cancer diagnostic with deep learning schemes using multi-image modalities, *IEEE Access*, 8, 165779-165809.
- Mandapati, S., Kadry, S., Kumar, R. L., Sutham, K., & Thinnukool, O., 2022, Deep learning model construction for a semi-supervised classification with feature learning, *Complex & Intelligent Systems*, 1-11.
- Mandelkow, H., De Zwart, J. A., & Duyn, J. H., 2016, Linear discriminant analysis achieves high classification accuracy for the BOLD fMRI response to naturalistic movie stimuli, *Frontiers in human neuroscience*, 10, 128.
- Mann, R. M., Kuhl, C. K., Kinkel, K., & Boetes, C., 2008, Breast MRI: guidelines from the European society of breast imaging, *European radiology*, 18(7), 1307-1318.
- Maqsood, S., Damaševičius, R., & Maskeliūnas, R., 2022, TTCNN: A Breast Cancer Detection and Classification towards Computer-Aided Diagnosis Using Digital Mammography in Early Stages, *Applied Sciences*, 12(7), 3273.
- Maspero, M., Houweling, A. C., Savenije, M. H., van Heijst, T. C., Verhoeff, J. J., Kotte, A. N., & van den Berg, C. A., 2020, A single neural network for cone-beam computed tomography-based radiotherapy of head-and-neck, lung and breast cancer, *Physics and imaging in radiation oncology*, 14, 24-31.
- Melekoodappattu, J. G., Dhas, A. S., Kandathil, B. K., & Adarsh, K. S., 2022, Breast cancer detection in mammogram: Combining modified CNN and texture feature based approach, *Journal of Ambient Intelligence and Humanized Computing*, 1-10.
- Menezes, G. L., Knuttel, F. M., Stehouwer, B. L., Pijnappel, R. M., & van den Bosch, M. A., 2014, Magnetic resonance imaging in breast cancer: a literature review and future perspectives, *World journal of clinical oncology*, 5(2), 61.
- Menon, V., & Pingali, K., 1999, A case for source-level transformations in MATLAB, *In Proceedings of the 2nd conference on Domain-specific languages*, 53-65.
- Mescher, A., 2013, Junqueira's Basic Histology: Text and Atlas. New York, NY, USA: McGraw-Hill.
- Mittal, U., Srivastava, S., & Chawla, P., 2019, Review of different techniques for object detection using deep learning, *In Proceedings of the third international conference on advanced informatics for computing research*, 1-8.
- Mohamed, A., Amer, E., Eldin, N., Hossam, M., Elmasry, N., & Adnan, G. T., 2022, The impact of data processing and ensemble on breast cancer detection using

- deep learning, *Journal of Computing and Communication*, 1(1), 27-37.
- Moloney, B. M., O'Loughlin, D., Abd Elwahab, S., & Kerin, M. J., 2020, Breast cancer detection-A synopsis of conventional modalities and the potential role of microwave imaging, *Diagnostics*, 10(2), 103.
- Moss, S. M., Cuckle, H., Evans, A., Johns, L., Waller, M., & Bobrow, L., 2006, Effect of mammographic screening from age 40 years on breast cancer mortality at 10 years' follow-up: a randomised controlled trial, *The Lancet*, 368(9552), 2053-2060.
- Mostafa, A., Houssein, E. H., Houseni, M., Hassanien, A. E., & Hefny, H., 2018, Evaluating swarm optimization algorithms for segmentation of liver images, *In Advances in soft computing and machine learning in image processing*, Springer, Cham, 41-62.
- Mridha, M. F., Hamid, M., Monowar, M. M., Keya, A. J., Ohi, A. Q., Islam, M., & Kim, J. M., 2021, A comprehensive survey on deep-learning-based breast cancer diagnosis, *Cancers*, 13(23), 6116.
- Mushtaq, Z., Yaqub, A., Sani, S., & Khalid, A., 2020, Effective K-nearest neighbor classifications for Wisconsin breast cancer data sets, *Journal of the Chinese Institute of Engineers*, 43(1), 80-92.
- Muzaki, K., BreaKHis 400X, Kaggle Web. (2020). <https://www.kaggle.com/datasets/forderation/breakhis-400x?resource=download>. [Ziyaret Tarihi: 9 Ağustos 2022].
- Nasim, S. F., Ali, M. R., & Kulsoom, U., 2022, Artificial Intelligence Incidents & Ethics A Narrative Review. *International Journal of Technology, Innovation and Management (IJTIM)*, 2(2).
- Nassif, A. B., Talib, M. A., Nasir, Q., Afadar, Y., & Elgendy, O., 2022, Breast cancer detection using artificial intelligence techniques: A systematic literature review, *Artificial Intelligence in Medicine*, 102276.
- Nassif, A. B., Talib, M. A., Nasir, Q., Afadar, Y., & Elgendy, O., 2022, Breast cancer detection using artificial intelligence techniques: A systematic literature review, *Artificial Intelligence in Medicine*, 102276.
- Nichols, J. A., Herbert Chan, H. W., & Baker, M. A., 2019, Machine learning: applications of artificial intelligence to imaging and diagnosis, *Biophysical reviews*, 11(1), 111-118.
- Niu, Z., Zhong, G., & Yu, H., 2021, A review on the attention mechanism of deep learning, *Neurocomputing*, 452, 48-62.
- Niwatkar, A., & Kanse, Y. K., 2020, Feature Extraction using Wavelet Transform and Euclidean Distance for speaker recognition system, *In 2020 International Conference on Industry 4.0 Technology (I4Tech)*, IEEE, 145-147.
- Niu, Z., Zhong, G., & Yu, H., 2021, A review on the attention mechanism of deep

- learning, *Neurocomputing*, 452, 48-62.
- Olier, I., Orhobor, O. I., Dash, T., Davis, A. M., Soldatova, L. N., Vanschoren, J., & King, R. D., 2021, Transformational machine learning: Learning how to learn from many related scientific problems, *Proceedings of the National Academy of Sciences*, 118(49), e2108013118.
- Orru, G., Pettersson-Yeo, W., Marquand, A. F., Sartori, G., & Mechelli, A., 2012, Using support vector machine to identify imaging biomarkers of neurological and psychiatric disease: a critical review, *Neuroscience & Biobehavioral Reviews*, 36(4), 1140-1152.
- Ortega-Martorell, S., Riley, P., Olier, I., Raidou, R. G., Casana-Eslava, R., Rea, M., ... & Palmieri, C., 2022, Breast cancer patient characterisation and visualisation using deep learning and fisher information networks, *Scientific Reports*, 12(1), 1-14.
- Osman, A. E. H., 2018, Brain Tumors Detection using Artificial Neural Networks (Doctoral dissertation, Sudan University of Science and Technology).
- Ouahabi, A., & Taleb-Ahmed, A., 2021, Deep learning for real-time semantic segmentation: Application in ultrasound imaging, *Pattern Recognition Letters*, 144, 27-34.
- Oza, P., Sharma, P., Patel, S., & Kumar, P., 2022, Deep convolutional neural networks for computer-aided breast cancer diagnostic: a survey, *Neural Computing and Applications*, 1-22.
- Ozer, M. E., Sarica, P. O., & Arga, K. Y., 2020, New machine learning applications to accelerate personalized medicine in breast cancer: rise of the support vector machines, *Omics: a journal of integrative biology*, 24(5), 241-246.
- Papamarkou, T., Hinkle, J., Young, M. T., & Womble, D., 2022,. Challenges in Markov chain Monte Carlo for Bayesian neural networks, *Statistical Science*, 37(3), 425-442.
- Park, S. H., & Han, K., 2018, Methodologic guide for evaluating clinical performance and effect of artificial intelligence technology for medical diagnosis and prediction, *Radiology*, 286(3), 800-809.
- Parvat, A., Chavan, J., Kadam, S., Dev, S., & Pathak, V., 2017, A survey of deep-learning frameworks, *In 2017 International Conference on Inventive Systems and Control (ICISC)*, IEEE, 1-7.
- Paul, D., Sanap, G., Shenoy, S., Kalyane, D., Kalia, K., & Tekade, R. K., 2021, Artificial intelligence in drug discovery and development, *Drug discovery today*, 26(1), 80.
- Peñafiel, E. F. M., Barahona, B. V., & Camejo, I. M., 2018, Methodology of Building An Expert System Using Induction Rules with Structured Programming, *KnE Engineering*, 235-254.

- Peng, S., Huang, H., Chen, W., Zhang, L., & Fang, W., 2020, More trainable inception-ResNet for face recognition, *Neurocomputing*, 411, 9-19.
- Pesapane, F., Codari, M., & Sardanelli, F., 2018, Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine, *European radiology experimental*, 2(1), 1-10.
- Pharswan, R., & Singh, J., 2020, Performance Analysis of SVM and KNN in Breast Cancer Classification: A Survey, *In Internet of Things and Big Data Applications*, Springer, Cham, 133-140.
- Quinto, B., 2020, Introduction to machine learning, *In Next-Generation Machine Learning with Spark*, Apress, Berkeley, CA., 1-27.
- Raaj, R. S., 2023, Breast cancer detection and diagnosis using hybrid deep learning architecture, *Biomedical Signal Processing and Control*, 82, 104558.
- Ragab, D. A., Sharkas, M., & Attallah, O., 2019, Breast cancer diagnosis using an efficient CAD system based on multiple classifiers, *Diagnostics*, 9(4), 165.
- Rajaraman, V., 2014, JohnMcCarthy—Father of artificial intelligence, *Resonance*, 19(3), 198-207.
- Reenadevi, R., Sathiya, T., & Sathiyabhama, B., 2021, Breast cancer histopathological image classification using augmentation based on optimized deep ResNet-152 structure, *Annals of the Romanian Society for Cell Biology*, 25(6), 5866-5874.
- Ribani, R., & Marengoni, M., 2019, A survey of transfer learning for convolutional neural networks, *In 2019 32nd SIBGRAPI conference on graphics, patterns and images tutorials (SIBGRAPI-T)*, IEEE, 47-57.
- Robertson, S., Azizpour, H., Smith, K., & Hartman, J., 2018, Digital image analysis in breast pathology-from image processing techniques to artificial intelligence, *Translational Research*, 194, 19-35.
- Rodrigues, É. O., 2018, Combining Minkowski and Chebyshev: New distance proposal and survey of distance metrics using k-nearest neighbours classifier, *Pattern Recognition Letters*, 110, 66-71.
- Saber, A., Sakr, M., Abo-Seida, O. M., Keshk, A., & Chen, H., 2021, A novel deep-learning model for automatic detection and classification of breast cancer using the transfer-learning technique, *IEEE Access*, 9, 71194-71209.
- Sahu, M., & Dash, R., 2021, A survey on deep learning: convolution neural network (CNN), *In Intelligent and Cloud Computing: Proceedings of ICICC 2019*, Springer Singapore, 2, 317-325.
- Samala, R. K., Chan, H. P., Hadjiiski, L., Helvie, M. A., Richter, C. D., & Cha, K. H., 2018, Breast cancer diagnosis in digital breast tomosynthesis: effects of training sample size on multi-stage transfer learning using deep neural nets, *IEEE transactions on medical imaging*, 38(3), 686-696.

- Sechopoulos, I., Teuwen, J., & Mann, R., 2021, Artificial intelligence for breast cancer detection in mammography and digital breast tomosynthesis: State of the art, *In Seminars in Cancer Biology*, Academic Press., 72, 214-225.
- Serin, Z., 2020, Meme kanserinin histopatolojik görüntüler üzerinde derin sinir ağları kullanılarak bilgisayar destekli otomatik tespiti, *Master's thesis, Bilecik Şeyh Edebali Üniversitesi*, Fen Bilimleri Enstitüsü.
- Seo, J., & Kim, Y. S., 2017, Ultrasound imaging and beyond: recent advances in medical ultrasound, *Biomedical Engineering Letters*, 7(2), 57-58.
- Sewak, M., Vaidya, P., Chan, C. C., & Duan, Z. H., 2007, SVM approach to breast cancer classification, *In Second International Multi-Symposiums on Computer and Computational Sciences (IMSCCS 2007)*, IEEE, 32-37.
- Shah, S. M., Khan, R. A., Arif, S., & Sajid, U., 2022, Artificial intelligence for breast cancer analysis: Trends & directions, *Computers in Biology and Medicine*, 105221.
- Shahidi, F., Daud, S. M., Abas, H., Ahmad, N. A., & Maarop, N., 2020, Breast cancer classification using deep learning approaches and histopathology image: a comparison study, *Ieee Access*, 8, 187531-187552.
- Shaikh, F., Dehmeshki, J., Bisdas, S., Roettger-Dupont, D., Kubassova, O., Aziz, M., & Awan, O., 2021, Artificial intelligence-based clinical decision support systems using advanced medical imaging and radiomics, *Current Problems in Diagnostic Radiology*, 50(2), 262-267.
- Sharma, N., Sharma, R., & Jindal, N., 2021, Machine learning and deep learning applications-a vision, *Global Transitions Proceedings*, 2(1), 24-28.
- Sharma, S., Aggarwal, A., & Choudhury, T., 2018, Breast cancer detection using machine learning algorithms, *In 2018 International conference on computational techniques, electronics and mechanical systems (CTEMS)*, IEEE, 114-118.
- Sheth, D., & Giger, M. L., 2020, Artificial intelligence in the interpretation of breast cancer on MRI, *Journal of Magnetic Resonance Imaging*, 51(5), 1310-1324.
- Shia, W. C., Lin, L. S., & Chen, D. R., 2021, Classification of malignant tumours in breast ultrasound using unsupervised machine learning approaches, *Scientific Reports*, 11(1), 1-11.
- Shravya, C., Pravalika, K., & Subhani, S., 2019, Prediction of breast cancer using supervised machine learning techniques, *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 8(6), 1106-1110.
- Shrestha, A., & Mahmood, A., 2019, Review of deep learning algorithms and architectures, *IEEE access*, 7, 53040-53065.
- Sivakumar, S., Nayak, S. R., Vidyanandini, S., Kumar, J. A., & Palai, G., 2018, An empirical study of supervised learning methods for breast cancer diseases, *Optik*, 175, 105-114.

- Spanhol, F. A., Oliveira, L. S., Petitjean, C., & Heutte, L., 2015, A dataset for breast cancer histopathological image classification, *Ieee transactions on biomedical engineering*, 63(7), 1455-1462.
- Spänig, S., Emberger-Klein, A., Sowa, J. P., Canbay, A., Menrad, K., & Heider, D., 2019, The virtual doctor: an interactive clinical-decision-support system based on deep learning for non-invasive prediction of diabetes, *Artificial intelligence in medicine*, 100, 101706.
- Stachs, A., Stubert, J., Reimer, T., & Hartmann, S., 2019, Benign breast disease in women, *Deutsches Ärzteblatt International*, 116(33-34), 565.
- Subasi, A., & Gursoy, M. I., 2010, EEG signal classification using PCA, ICA, LDA and support vector machines, *Expert systems with applications*, 37(12), 8659-8666.
- Szolovits, P., Patil, R. S., & Schwartz, W. B., 1988, Artificial intelligence in medical diagnosis, *Annals of internal medicine*, 108(1), 80-87.
- Şengür, A., 2008, An expert system based on linear discriminant analysis and adaptive neuro-fuzzy inference system to diagnosis heart valve diseases, *Expert Systems with Applications*, 35(1-2), 214-222.
- Takeda, T., Momose, A., Ueno, E. I., & Itai, Y., 1998, Phase-contrast X-ray CT image of breast tumor, *Journal of synchrotron radiation*, 5(3), 1133-1135.
- Talari, A. C., Rehman, S., & Rehman, I. U., 2019, Advancing cancer diagnostics with artificial intelligence and spectroscopy: identifying chemical changes associated with breast cancer, *Expert Review of Molecular Diagnostics*, 19(10), 929-940.
- Thilagaraj, M., Arunkumar, N., & Govindan, P., 2022, Classification of breast cancer images by implementing improved dcnn with artificial fish school model, *Computational Intelligence and Neuroscience*, vol. 2022.
- Toğaçar, M., & Ergen, B., 2019, Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 109-121.
- Toğaçar, M., Ergen, B., & Cömert, Z., 2021, Tumor type detection in brain MR images of the deep model developed using hypercolumn technique, attention modules, and residual blocks, *Medical & Biological Engineering & Computing*, 59(1), 57-70.
- Tsochatzidis, L., Costaridou, L., & Pratikakis, I., 2019, Deep learning for breast cancer diagnosis from mammograms-a comparative study, *Journal of Imaging*, 5(3), 37.
- Turgut, S., 2017, Makine öğrenmesi yöntemleri kullanarak kanser teşhisi, *Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü*, İstanbul.
- Türk, F., Lüy, M., & Barışçı, N., 2019, Böbrek Tümör Segmentasyonu İçin Unet ve Unet-ResNet Modellerinin Karşılaştırılması, *In 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, IEEE, 1-5.

- Ueda, D., Shimazaki, A., & Miki, Y., 2019, Technical and clinical overview of deep learning in radiology, *Japanese journal of radiology*, 37(1), 15-33.
- Vaka, A. R., Soni, B., & Reddy, S., 2020, Breast cancer detection by leveraging Machine Learning, *ICT Express*, 6(4), 320-324.
- Van Sloun, R. J., Cohen, R., & Eldar, Y. C., 2019, Deep learning in ultrasound imaging, *Proceedings of the IEEE*, 108(1), 11-29.
- Vapnik, V. N., 1999, An overview of statistical learning theory, *IEEE transactions on neural networks*, 10(5), 988-999.
- Vijayarajeswari, R., Parthasarathy, P., Vivekanandan, S., & Basha, A. A., 2019, Classification of mammogram for early detection of breast cancer using SVM classifier and Hough transform, *Measurement*, 146, 800-805.
- Vo, D. M., Nguyen, N. Q., & Lee, S. W., 2019, Classification of breast cancer histology images using incremental boosting convolution networks, *Information Sciences*, 482, 123-138.
- Waks, A. G., & Winer, E. P., 2019, Breast cancer treatment: a review, *Jama*, 321(3), 288-300.
- Wang, H., Zheng, B., Yoon, S. W., & Ko, H. S., 2018, A support vector machine-based ensemble algorithm for breast cancer diagnosis, *European Journal of Operational Research*, 267(2), 687-699.
- Wang, P., Fan, E., & Wang, P., 2021, Comparative analysis of image classification algorithms based on traditional machine learning and deep learning, *Pattern Recognition Letters*, 141, 61-67.
- Wang, Y., Ge, X., Ma, H., Qi, S., Zhang, G., & Yao, Y., 2021, Deep learning in medical ultrasound image analysis: a review, *IEEE Access*, 9, 54310-54324.
- Warner, E., 2011, Breast-cancer screening, *New England Journal of Medicine*, 365(11), 1025-1032.
- Warner, E., Causer, P. A., Wong, J. W. N., Wright, F. C., Jong, R. A., Hill, K. A., ... & Plewes, D. B., 2011, Improvement in DCIS detection rates by MRI over time in a high-risk breast screening study, *The breast journal*, 17(1), 9-17.
- Woodard, P. K., Bluemke, D. A., Cascade, P. N., Finn, J. P., Stillman, A. E., Higgins, C. B., ... & Yucel, E. K., 2006, ACR practice guideline for the performance and interpretation of cardiac magnetic resonance imaging (MRI), *Journal of the American College of Radiology*, 3(9), 665-676.
- Wu, H., Wang, L., Zhao, Z., Shu, C., & Lu, C., 2018, Support vector machine based differential pulse-width pair Brillouin optical time domain analyzer, *IEEE Photonics Journal*, 10(4), 1-11.
- Yang, L., Chen, X., Perlaza, S. M., & Zhang, J., 2020, Special issue on artificial-intelligence-powered edge computing for Internet of Things, *IEEE Internet of*

Things Journal, 7(10), 9224-9226.

- Yue, W., Wang, Z., Chen, H., Payne, A., & Liu, X., 2018, Machine learning with applications in breast cancer diagnosis and prognosis, *Designs*, 2(2), 13.
- Zahoor, S., Lali, I. U., Khan, M. A., Javed, K., & Mehmood, W., 2020, Breast cancer detection and classification using traditional computer vision techniques: a comprehensive review, *Current Medical Imaging*, 16(10), 1187-1200.
- Zahoor, S., Shoaib, U., & Lali, I. U., 2022, Breast Cancer Mammograms Classification Using Deep Neural Network and Entropy-Controlled Whale Optimization Algorithm, *Diagnostics*, 12(2), 557.
- Zerouaoui, H., & Idri, A., 2021, Reviewing machine learning and image processing based decision-making systems for breast cancer imaging, *Journal of Medical Systems*, 45(1), 1-20.
- Zhang, X., He, D., Zheng, Y., Huo, H., Li, S., Chai, R., & Liu, T., 2020, Deep learning based analysis of breast cancer using advanced ensemble classifier and linear discriminant analysis, *IEEE Access*, 8, 120208-120217.
- Zhang, X., Zhang, Y., Han, E. Y., Jacobs, N., Han, Q., Wang, X., & Liu, J., 2018, Classification of whole mammogram and tomosynthesis images using deep convolutional neural networks, *IEEE transactions on nanobioscience*, 17(3), 237-242.
- Zhang, Y. D., Satapathy, S. C., Guttery, D. S., Górriz, J. M., & Wang, S. H., 2021, Improved breast cancer classification through combining graph convolutional network and convolutional neural network, *Information Processing & Management*, 58(2), 102439.
- Zhang, Z., Li, Y., Wu, W., Chen, H., Cheng, L., & Wang, S., 2021, Tumor detection using deep learning method in automated breast ultrasound, *Biomedical signal processing and control*, 68, 102677.
- Zheng, J., Lin, D., Gao, Z., Wang, S., He, M., & Fan, J., 2020, Deep learning assisted efficient AdaBoost algorithm for breast cancer detection and early diagnosis, *IEEE Access*, 8, 96946-96954.
- Zhu, Y., Yang, L., & Shen, H., 2021, Value of the application of CE-MRI radiomics and machine learning in preoperative prediction of sentinel lymph node metastasis in breast cancer, *Frontiers in Oncology*, 11.
- Xu, Y., Wang, Y., & Razmjoooy, N., 2022, Lung cancer diagnosis in CT images based on Alexnet optimized by modified Bowerbird optimization algorithm, *Biomedical Signal Processing and Control*, 77, 103791.
- Xu, Y., Liu, X., Cao, X., Huang, C., Liu, E., Qian, S., & Zhang, J., 2021, Artificial intelligence: A powerful paradigm for scientific research, *The Innovation*, 2(4), 100179.

8. ÖZGEÇMİŞ

Kişisel Bilgiler:

Adı Soyadı : Feyzi Ferat ATEŞ

Eğitim Durumu

Lise : Tes-İş Anadolu Lisesi, 2010

Lisans :Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, 2014

YAYINLAR

Ulusal hakemli dergilerde yayımlanmış makale

1. Çalışkan, Abidin; Ateş, Feyzi Ferat; Toğaçar, Mesut, “Ultrason Tabanlı Meme Kanseri Görüntülerinin Derin Öğrenme Yaklaşımları ile Sınıflandırılması”, Fırat Üniversitesi Fen Bilimleri Dergisi, 34(2), pp. 121-129, 2022.
2. Çalışkan, Abidin; Ateş, Feyzi Ferat; Toğaçar, Mesut, “Meme Kanserinin Tespiti için Yapay Zekâ Tabanlı Hibrit Bir Model Önerisi”, Fırat Üniversitesi Fen Bilimleri Dergisi, 34(2), pp. 131-141, 2022.

Uluslararası kongre ve sempozyumlarda sunulan bildiriler

1. Ateş, Feyzi Ferat; Çalışkan, Abidin, “Using Deep Learning Methods to Breast Cancer Detection”, International Informatics Congress (IIC2022), pp. 245-254, 2022.
2. Ateş, Feyzi Ferat; Çalışkan, Abidin, “Denoising Methods Applications in 3D Medical Images”, International Conference on Engineering, Natural and Applied Science 2021 (ICENAS’21), pp. 21-25, 2021.
3. Ateş, Feyzi Ferat; Çalışkan, Abidin, “An Overview of Denoising Methods in Medical Images”, International Symposium of Scientific Research and Innovative Studies (ISSRIS’21), pp. 538-549, 2021.