T.C.
SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
HAMİDİYE SAĞLIK BİLİMLERİ ENSTİTÜSÜ

TIBBİ CİHAZ ENVANTER DOĞRULAMASINDA YAPAY ZEKÂ TABANLI SINIFLANDIRMA UYGULAMASI

BÜŞRA ÇELİK SARIYERLİOĞLU

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ NEDİM MUZOĞLU

SAĞLIK BİLİŞİM SİSTEMLERİ ANA BİLİM DALI
SAĞLIK BİLİŞİMİ YÜKSEK LİSANS PROGRAMI

YÜKSEK LİSANS TEZİ
EKİM/2025

İTHAF

Hayatım boyunca yanımda olan aileme ve anısıyla bana yön veren anneme ithaf ediyorum.

TEŞEKKÜR

Bu tez çalışmasının hazırlanmasında akademik bilgi birikimiyle rehberlik eden, yönlendirmeleri ve desteğiyle sürecin her aşamasında katkı sağlayan danışmanım Dr. Öğr. Üyesi Nedim Muzoğlu'na;

Süreç boyunca anlayışı ve desteğiyle yanımda olan eşim Yahya Kemal Sarıyerlioğlu'na;

Moral ve motivasyon anlamında desteğini hiçbir zaman esirgemeyen değerli arkadaşım Ayşe Kuşcu'ya;

Hemşirelik mesleğini icra ettiğim dönemde, Ümraniye Eğitim ve Araştırma Hastanesinde birlikte çalıştığım tüm çalışma arkadaşlarıma,

Eğitim hayatım boyunca bana her zaman destek olmuş, bugünlere gelmemde önemli payı bulunan, rahmetle andığım anneme içten şükranlarımı sunarım.

İÇİNDEKİLER

İTHAF iv
TEŞEKKÜR v
İÇİNDEKİLER vi
TABLOLAR LİSTESİ viii
ŞEKİLLER LİSTESİ ix
SİMGELER VE KISALTMALAR x
ÖZET xi
ABSTRACT xii
1. GİRİŞ 1
2. GENEL BİLGİLER 3
2.1. TIBBİ CİHAZ TANIMI 3
2.2. TIBBİ CİHAZLARIN SAĞLIK SEKTÖRÜNDEKİ KONUMU 4
2.3. TIBBİ CİHAZ YÖNETİMİ 4
2.4. TIBBİ CİHAZ ENVANTER YÖNETİMİ 5
2.5. ÇALIŞMA KAPSAMINDA İNCELENEN TIBBİ CİHAZLAR 6
2.5.1. Anestezi Cihazı 7
2.5.2. Hasta Başı Monitörü 7
2.5.3. Ventilasyon Cihazı 8
2.5.4. Fetal Monitör 9
2.5.5. Kalp Akım Grafiği Cihazı 10
2.6. YAPAY ZEKÂNIN TANIMI 10
2.7. MEDİKAL ALANDA YAPAY ZEKÂ UYGULAMALARI 11
2.7.1. Tanı Alanında Yapay Zekâ 11
2.7.2. Tedavi Planlamasında Yapay Zekâ 12
2.7.3. Tıbbi Görüntülemede Yapay Zekâ 13
2.8. MAKİNE ÖĞRENİMİNİN TANIMI 14
2.9. TEMEL MAKİNE ÖĞRENİMİ YÖNTEMLERİ 14
2.10. MAKİNE ÖĞRENİMİ ALGORİTMALARI 15
2.11. ÖZELLİK SEÇİMİ 15
2.12. DERİN ÖĞRENME 15
2.13. YAPAY SİNİR AĞLARININ ÇALIŞMA PRENSİBİ 16
2.14. YAPAY SİNİR AĞININ ÖĞRENME SÜRECİ 17
2.15. EVRİŞİMSEL SİNİR AĞLARININ TANIMI 18
2.16. TEMEL ESA MİMARİLERİ 18
2.17. TRANSFER ÖĞRENME 19

2.18. PERFORMANS METRİKLERİ 19
3. GEREÇ VE YÖNTEM 20
3.1. GEREÇ 20
3.1.1. Veri Seti 20
3.1.2. Tez Çalışması Esnasında Kullanılan Programlar 22
3.2. YÖNTEM 22
3.2.1. Görüntü Artırma Teknikleri 23
3.2.1.1. Döndürme 23
3.2.1.2. Çevirme 23
3.2.1.3. Yakınlaştırma 24
3.2.1.4. Parlaklık ayarı 24
3.2.1.5. Kontrast değişikliği 24
3.2.2. Özniteliklerin Elde Edilmesi ve Birleştirilmesi 24
3.2.2.1. VGG16 25
3.2.2.2. ResNet-50 25
3.2.3. Öznitelik Seçim Süreci 25
3.2.3.1. Hızlı Minimum Fazlalık Maksimum Alaka Algoritması 25
3.2.4. Sınıflandırma Süreci 26
3.2.4.1. Destek Vektör Makineleri 26
3.2.4.2. K En Yakın Komşu Algoritması 26
4. BULGULAR 27
4.1. PERFORMANS DEĞERLENDİRMESİ 27
5. TARTIŞMA 32
6. SONUÇLAR 51
KAYNAKLAR 53

TABLOLAR LİSTESİ

Tablo 3.1: Medikal Cihaz 5 veri seti örnek sayılarının dağılımı 20

Tablo 3.2: Görüntü artırma teknikleri sonrasında Medikal Cihaz 5 veri sayıları 22

Tablo 4.1: VGG16 ve ResNet-50 modellerinden elde edilen özniteliklerin Destek Vektör Makinesi ile sınıflandırılmasına ilişkin sonuçlar 28

Tablo 4.2: VGG16 ve ResNet-50 modellerinden elde edilen özniteliklerin K En Yakın Komşu ile sınıflandırılmasına ilişkin sonuçlar 28

Tablo 4.3: Öznitelik seçimi sonrasında Destek Vektör Makinesi algoritması ile sınıflandırma sonuçları 30

Tablo 4.4: Öznitelik seçimi sonrasında K En Yakın Komşu algoritması ile sınıflandırma sonuçları 30

ŞEKİLLER LİSTESİ

Şekil 2.1: Anestezi cihazı 7

Şekil 2.2: Hasta başı monitörü 8

Şekil 2.3: Ventilasyon cihazı 9

Şekil 2.4: Fetal monitör 9

Şekil 2.5: Kalp akım grafiği cihazı 10

Şekil 2.6: Yapay sinir ağları mimarisi 16

Şekil 2.7: Evrişimsel sinir ağları çalışma prensibi 18

Şekil 3.1: Medikal Cihaz 5 veri seti her bir cihaz türüne ait örnekler. (a) Anestezi cihazı, (b) Ventilatör, (c) Hasta başı monitör (d) Kalp akım grafiği cihazı, (e) Fetal monitör 21

Şekil 3.2: Medikal Cihaz 5 veri setindeki örneklerin iki boyutlu dağılım 21

Şekil 3.3: Medikal cihaz sınıflandırma çalışmasına ait akış diyagramı 23

Şekil 4.1: Medikal Cihaz 5 veri seti karmaşıklık matrisleri **(a)** ve **(d)** VGG16 özniteliklerinin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması **(b)** ve **(e)** ResNet-50 özniteliklerinin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması **(c)** ve **(f)** VGG16 ve ResNet-50 özniteliklerinin birleştirilip Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması 27

Şekil 4.2: Medikal Cihaz 5 veri seti birleştirilmiş özniteliklerin seçimi sonrası karmaşıklık matrisleri **(a)** ve **(d)** Seçilen 100 özniteliğin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması **(b)** ve **(e)** Seçilen 200 özniteliğin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması **(c)** ve **(f)** Seçilen 300 özniteliğin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması 29

Şekil 4.3: Medikal Cihaz 5 veri seti 300 öznitelik için sınıflandırma sonucu Alıcı İşletim Karakteristiği eğrisi 31

SİMGELER VE KISALTMALAR

AUC : Area Under Curve (Eğri Altında Kalan Alan)

EKG : Kalp Akım Grafiği

ESA : Evrişimsel Sinir Ağları

fMRMR : Fast Minimum Redundancy Maximum Relevance (Hızlı Minimum Fazlalık Maksimum Alaka)

GAN : Generative Adversarial Network (Üretici Çekişmeli Ağ)

IoT : Internet of Things (Nesnelerin İnterneti)

KNN : K Nearest Neighbor (K En Yakın Komşu)

MRI : Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)

RFE : Recursive Feature Elimination (Yineli Öznitelik Eleme)

ROC : Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)

SVM : Support Vector Machine (Destek Vektör Makinesi)

YSA : Yapay Sinir Ağları

TIBBİ CİHAZ ENVANTER DOĞRULAMASINDA İÇERİK TABANLI GÖRÜNTÜ ERİŞİM SİSTEMLERİ UYGULANMASI

ÖZET

Amaç: Bu tez çalışmasının amacı, tıbbi cihazların sınıflandırılmasına yönelik yapay zekâ tabanlı bir model geliştirmektir. Beş farklı türdeki tıbbi cihazlara ait görüntülerden öznitelik çıkarımı için VGG16 ve ResNet-50 gibi derin öğrenme modelleri kullanılmıştır. Sınıflandırmada ise Destek Vektör Makineleri (SVM) ve K En Yakın Komşu (KNN) gibi makine öğrenmesi algoritmalarına başvurulmuştur. Ayrıca öznitelik birleştirme ve seçme yöntemleri uygulanarak modelin doğruluk, duyarlılık ve kesinlik gibi performans ölçütleri değerlendirilmiştir. Çalışma, tıbbi cihaz envanter yönetiminde yapay zekâ tabanlı çözümlerin yaygınlaştırılmasını amaçlamaktadır.

Gereç ve Yöntem: Çalışmada, Kaggle platformundan temin edilen 'Medikal Cihaz 5' görüntü veri seti kullanılmıştır. Veri seti; anestezi cihazı, ventilatör, kalp akım grafiği cihazı, hasta başı monitörü ve fetal monitöre ait görüntüleri içermektedir. Veri kümesi eğitim, doğrulama ve test alt gruplarına ayrılmıştır. Eğitim setinde görüntü artırma yöntemiyle dengesizlik giderilmiştir. Öznitelik çıkarımı için VGG16 ve ResNet-50 modellerinden yararlanılmıştır. Ardından fMRMR yöntemiyle en anlamlı 100, 200 ve 300 öznitelik seçilmiştir.

Bulgular: VGG16 ve ResNet-50 özniteliklerinin birleştirilmesiyle %94,7 doğruluk elde edilmiştir. 200 öznitelik ile SVM algoritması %96,29, KNN ise %93,65 doğruluk sağlamıştır. SVM, tüm denemelerde KNN'ye göre daha yüksek performans göstermiştir.

Sonuç: Bu çalışma, tıbbi cihazların sınıflandırılmasında yapay zekâ temelli yaklaşımların etkili olduğunu göstermiştir. Farklı derin öğrenme modellerinden elde edilen özniteliklerin birleştirilerek geleneksel makine öğrenmesi algoritmalarıyla entegre edilmesi, sınıflandırma performansını artırmıştır. Elde edilen model, doğru ve hızlı envanter yapılanmasına katkı sağlayarak sağlık kuruluşlarında yapay zekâ tabanlı sistemlerin uygulanabilirliğine yönelik önemli bir adım sunmaktadır.

Anahtar Kelimeler: Derin Öğrenme, Makine Öğrenmesi, Tıbbi Cihaz, Yapay Zekâ

CONTENT BASED IMAGE RETRIEVAL FOR MEDICAL DEVICE INVENTORY VERIFICATION

ABSTRACT

Aim: This thesis aims to develop an artificial intelligence (AI)-based model for classifying medical devices. Deep learning models such as VGG16 and ResNet-50 were utilized to extract features from images of five different medical device types. SVM and KNN algorithms were employed for classification. Additionally, feature fusion and selection methods were applied, and performance metrics such as accuracy, sensitivity, and precision were evaluated. This study promotes the adoption of AI-based solutions in medical device inventory management.

Materials and Methods: In this study, the "Medical Device 5" image dataset obtained from the Kaggle platform was used. The dataset includes images of anesthesia machines, ventilators, ECG devices, patient monitors, and fetal monitors. The dataset includes images of anesthesia machines, ventilators, electrocardiographs, patient monitors, and fetal monitors. The dataset was split into training, validation, and test subsets. Data augmentation was performed to address class imbalance in the training set. Features were extracted using VGG16 and ResNet-50, and the most significant 100, 200, and 300 features were selected via the fMRMR method.

Results: Combining features from VGG16 and ResNet-50 achieved 94.7% accuracy. Using 200 features, SVM reached 96.29% accuracy, while KNN achieved 93.65%. SVM consistently outperformed KNN in all trials.

Conclusion: The study demonstrates that AI-based approaches are effective for classifying medical devices. Combining features from different deep learning models with traditional machine learning algorithms enhanced classification performance. The proposed model supports accurate and rapid inventory structuring, contributing significantly to the implementation of AI-based systems in healthcare.

Key Words: Artificial Intelligence, Deep Learning, Machine Learning, Medical Device

1. GİRİŞ

Günümüzde yaşlanan nüfusla birlikte sağlık hizmetlerine olan talep artmıştır (1). Sağlık hizmetlerinin sunumundaki temel yapı taşlarından biri de tıbbi cihazlardır. Tıbbi cihazlar hastalıkların tanı, teşhis ve takibinde önemli rol oynarlar (2). Günümüzde teknolojide yaşanan hızlı değişimler sağlık sektörünü de etkilemiştir. Artan bilgi birikimi ve gelişen teknoloji ile tıbbi cihazların çeşidi ve sayısı da artmıştır (3). Yüksek teknoloji ürünü olan bu cihazlar ülkemize ithal edilmekte olup oldukça pahalıdır (4). Cihazların düzenli takibi, bakım ve onarımlarının zamanında yapılması ve cihaz envanterinin güncel tutulması önemlidir. Medikal cihaz envanteri bir sağlık tesisinde bulunan tüm tıbbi cihazların kayıt alına alınıp izlendiği sistematik bir listedir (5). Biyomedikal personelleri tıbbi cihaz envanter yönetimiyle ilgilenmekte olup ülkemizde yeterli sayıda istihdama sahip değildir (6). Tıbbi cihaz sayısındaki artış ve çeşitlilik envanter yönetimini zorlaştırmaktadır. Mevcut personel eksikliği ile bu durum daha da güçleşmiştir. Alışılagelmiş olan envanter yöntemleri ve personel eksikliği cihazların takibinde yetersiz kalmakta ve hata oranını artırmaktadır (7).

Bilgisayarların hesaplama gücündeki artış ve veriye erişimdeki kolaylıklar bilgi teknolojilerinde yeni bir çağ açmıştır (8). Bu alanda özellikle göze çarpan uygulama alanlarından biri de yapay zekâdır. Yapay zekâ, insan zekâsını taklit ederek birçok soruna çözüm getirir (9). Makine öğrenimi ve derin öğrenme algoritmaları yapay zekânın temel, belli başlı alt dallarındandır. Makine öğreniminde veriler aracılığıyla eğitim gerçekleşir ve makinenin bu veriler üzerinden tahmin ve kararlar alması sağlanır (10). Derin öğrenme ise çok katmanlı sinir ağlarıyla çalışarak öğrenme gerçekleştirir (11). Derin öğrenmenin alt dallarından Evrişimsel Sinir Ağları (ESA), görüntülerle ilgilenen çok katmanlı ağ modelleridir. ESA, görüntülerdeki anlamlı özellikleri çıkartır ve onların neye ait olduğunu tahmin eder. Günümüzde birçok ESA modeli bulunmaktadır (12).

Bu tez çalışmasında yapay zekâ tabanlı modellerin, biyomedikal cihaz görsellerini yüksek doğruluk oranıyla sınıflandırıp sınıflandıramayacağının yanıtı bulunacaktır. Çalışmada görsel olarak birbirine benzeyen fetal monitör, hasta başı monitörü, anestezi cihazı, Kalp Akım Grafiği (EKG) cihazı ve ventilatör cihazına ilişkin görüntüler incelenecektir. Görüntüler test, doğrulama ve eğitim verisi olmak üzere üçe ayrılacaktır.

Eğitim veri setinde, veri arttırma yöntemine başvurularak dengesiz veri dağılımının önüne geçilmesi hedeflenmektedir. Görüntüler ESA mimarilerinden ResNet-50 ve VGG16 analiz edilecek olup çıkan sonuçlar ışığında öznitelik veri tabanı oluşturulacaktır. Modellerin tek başlarına ve birleşik haldeki öznitelikleri ayrı ayrı değerlendirilecektir. Gereksiz öznitelikler, Fast Minimum Redundancy Maximum Relevance- Hızlı Minimum Fazlalık Maksimum Alaka (fMRMR) yöntemiyle elimine edilecek, bu sayede en belirgin öznitelikler ortaya çıkarılacaktır. Bu aşamadan sonra görüntüler SVM ve KNN algoritmaları ile sınıflandırılacaktır. Medikal görüntü veri seti, öznitelik seçimi öncesi ve sonrası olmak üzere iki defa SVM ve KNN algoritmalarıyla sınıflandırılacaktır. Bu sayede öznitelik seçiminin model üzerindeki başarısı tespit edilecektir. Oluşturulan bu model sayesinde cihaz sınıflandırılmasında maksimum başarı hedeflenmektedir. Çıkan sonuçlar ışığında uygulanan algoritmalar kendi içinde kıyaslanacak ve en başarılı olan algoritma tespit edilecektir. Modellerin başarısı doğruluk, duyarlılık, kesinlik gibi metrikler ile değerlendirilecektir.

Çalışmanın birincil amacı, tıbbi cihaz envanter yapılanmasında veri girişi esnasında hatalı girilen cihaz türlerinin kontrolünün kolaylaşmasıdır. Ek olarak cihaz denetim ve takip süreçlerinin kolaylaşması, hızlı ve hatasız envanter yapılanmasının sağlanması, sağlık hizmetlerindeki kalite ve sürdürülebilirlikte artış amaçlanmaktadır. Çalışmanın sağlık ve bilişim teknolojileri arasında köprü kuracağı düşünülmekte olup biyomedikal alandaki insan kaynaklı envanter hatalarına yardımcı olması umulmaktadır.

2. GENEL BİLGİLER

Tıbbi cihazlar; doktorlar, hemşireler, diş hekimleri, odyologlar gibi çeşitli meslek gruplarınca kullanılmaktadır (13). Geliştirilen cihazlar sağlık teknolojilerinde yeni dönemler açmıştır.

Günümüzde tıbbi cihazlar, sağlıkla ilgili hemen her alanda kullanılmaktadır. Hem çeşit hem de sayı bakımından giderek artmıştır. Bu cihazlar hastalıkların tanı, tedavi ve diğer tüm süreçlerinde kullanılmaktadır (14). Farklı amaçlar için giderek özelleşmiştir. Basit bir ayak bileği bandajından, yapay kalça protezine ya da cerrahi bir operasyona kadar birçok işlem tıbbi cihazlar sayesinde yapılabilmektedir.

Dünya pazarında yaklaşık 2 milyon farklı türde tıbbi cihaz bulunduğu tahmin edilmektedir (15). Cihazların teşhis, tanı ve tedavide kullanımında hatalar olmaması için belli şartlar altında kontrolleri gerekir. Türkiye'de genellikle ithal edilen bu cihazlar oldukça masraflıdır (4). Cihazların doğru ve uzun ömürlü kullanılması için bakım, onarım ve kalibrasyonlarının düzenli şekilde yapılması gerekir. Cihazların takibinin kolaylaşması için bunlara özgü envanterler kullanılır (5). Cihazın tüm yaşam öyküsünün olduğu bu envanterlerin belli aralıklarla güncellenmesi gerekir. Cihaz takibi, yönetimi ve envanter işlemleri biyomedikal mühendisleri tarafından yapılır. Ülkemizde biyomedikal mühendislerine olan ihtiyaç karşılanamamaktadır (6). Yaşanan bu istihdam sorunu cihaz yönetimi ve envanter güncelliğini aksatabilir. Cihaz tanımlaması ve sınıflandırması sonucu daha hızlı bir envanter yapılanması oluşturabilir. Bu tanımlama ve sınıflandırma işleminde yapay zekâ algoritmaları kolaylık sağlayabilir. Bu sayede klinik ortamdaki tıbbi cihazların hızlı şekilde envanter sistemine geçirilmesinin ilk basamağı oluşturulur.

2.1. TIBBİ CİHAZ TANIMI

Dünya Sağlık Örgütüne göre tıbbi cihaz, üreticisinin tıbbi bir amaçla kullanılmak üzere tasarladığı herhangi bir alet, cihaz, makine, araç, malzeme veya benzeri bir üründür (16).

T.C. Sağlık Bakanlığının tanımında tıbbi cihazlar, insanlarda hastalıkları teşhis etmek, izlemek, tedavi etmek ya da önlemek için kullanılan araçlardır. Bu cihazlar, doğrudan ilaç gibi etki göstermez ama ilaçlarla birlikte çalışabilir. Alet, yazılım, ekipman veya aksesuar şeklinde olabilirler. Örneğin bir cihaz, vücut işlevlerini incelemek, bir

sorunu hafifletmek ya da doğum kontrolü amacıyla kullanılabilir. Bu cihazlarla birlikte çalışan yazılımlar da tıbbi cihaz sayılır (17).

2.2. TIBBİ CİHAZLARIN SAĞLIK SEKTÖRÜNDEKİ KONUMU

Sağlık hizmetlerine duyulan ihtiyaç kronik hastalıkların artması ve yaşlanan nüfusla birlikte gittikçe artmıştır. Yaşlanan nüfusla birlikte artan kronik hastalıklar erken teşhis ve tanının önemini arttırmaktadır. Hastalarda yaşam kalitesinin artması hedeflenmekte ve buna yönelik bir talep oluşmaktadır. Artan talep ve teknolojideki gelişmelerin giderek hızlanması sağlık sektöründe farklı özelleşmelerin olmasını tıbbi tanı ve teşhise uygun spesifik cihaz ve aletlerin kullanılmasını gerektirmiştir (1).

Gelişen teknolojiyle birlikte sağlık sektörü daha fazla teknolojiye bağımlı hale getirmiştir. Yaşanan bu süreç farklı özelliklerde cihazların gelişimine olanak sağlamıştır. Bu sayede hastalıkların tanı, teşhis ve tedavisi kolaylaşmıştır. Bununla birlikte kronik hastalıkların yönetimi de kolaylaşmıştır. Taşınabilir cihazlar ve uzaktan takip sistemleri, hastaların yaşam kalitesini arttırmış ve evden sağlık hizmeti almalarını sağlamıştır. Bu bağlamda tıbbi cihazlar sadece teknolojik bir unsur olarak değil, insan hayatını iyileştiren bir güç olarak da ele alınmalıdır (18).

Tıbbi cihazlar, sağlık hizmetinin sunumu ve işlerliği bakımından önemli yere sahiptir. Yüksek teknoloji ürünü olan tıbbi cihazlar uzun araştırma çalışmaları sonucu üretilmektedir. Yaşanan gelişmeler farklı disiplinlerden katılımcıları bir araya getirmiştir. Böylece sağlık sektörünün ekonomik pazar payındaki önemi artırmıştır. Sağlık işletmelerinde ayrılan bütçenin büyük bir kısmını tıbbi cihazların alım, bakım ve operasyonel maliyetler oluşturur. Tıbbi cihaz üretiminde teknolojiye önemli miktarda pay ayıran firmalar pazar payından büyük oranda yer almaktadır, bundan dolayı da rekabet olanakları sınırlı olabilmektedir (4).

2.3. TIBBİ CİHAZ YÖNETİMİ

Yönetim, bir işletmenin elindeki kaynakları planlı şekilde kullanmasıdır. Bu süreçte kaynaklar organize edilir, işler yürütülür ve sonuçlar kontrol edilir. Amaç, mevcut kaynakları etkili ve verimli bir şekilde kullanarak belirlenen hedeflere ulaşmaktır. (19).

Sağlık kuruluşları, emek yoğun işletmecilikten teknoloji yoğun işletmeciliğe geçiş yapmıştır. Bu geçiş sürecinde işletmeler, sundukları sağlık hizmetinin kalitesini korumak

isterler. İleri teknoloji ürünü olan tıbbi cihazların doğru şekilde kullanımı için tıbbi cihaz yönetiminin etkili ve verimli bir şekilde yürütülmesi gerekir (20).

Tıbbi cihazların yönetimi çeşitli faaliyetlerden oluşur. Bu süreç cihazların, maksimum kapasitede ve daha uzun ömürlü kullanılmasını sağlar. Tıbbi cihaz yönetiminin temel unsurları, planlama ve değerlendirme, bütçeleme ve finansman, montaj ve görevlendirme, satın alma, lojistik, bakım ve onarımdır (20).

Planlama, tıbbi cihaz yönetimi sürecinin temel adımıdır ve cihazın ne zaman, nerede, nasıl, kim tarafından ve hangi maliyetle tedarik edileceğini belirler. Bu süreç, biyomedikal mühendisliği birimi tarafından önemli ölçüde desteklenmektedir.

T.C. Sayıştay Başkanlığı, Sağlık Bakanlığına bağlı hastanelerde tıbbi cihaz yöntemi adına inceleme gerçekleştirmiştir. Yapılan incelemeler performans denetimi raporu olarak yayınlanmıştır. Raporda tıbbi cihazların atıl kapasitede kullanıldığı cihaz onarımında gecikmeler olduğu ve personel eksikliğinin olduğu belirtilmiştir (21).

Tıbbi cihaz gereksinimleri sağlık kuruluşuna bağlı alt birimlerce tespit edilir ve üst yönetime bilgi verilir. Cihaz taleplerinin yanlış tanımlanması veya yanlış bir cihazın tedarik edilmesi durumunda esas ihtiyaç sekteye uğrar. Bu da tıbbi cihaz yönetimi sürecindeki hataların zeminini oluşturur. Tıbbi cihazların doğru yönetimi, sağlık hizmetinin birim maliyetlerini indirir ve verimliliği arttırır (22). Bu cihazların yönetiminde biyomedikal mühendislerinin büyük önemi vardır. Biyomedikal mühendisleri tıbbi cihazların hatasız ve sürdürülebilir şekilde çalışmasını sağlar. Bunu yaparken cihazların belli standartlar altında, hassas ve hatasız ölçümler yapabilmesi için kalibrasyonlarını yapar. Bakım ve onarım işlemlerini gerçekleştirir. Cihazların donanımsal ve yazılımsal müdahalelerini yapar ve. cihaz envanterlerini güncel tutarlar (23). Bu sayede sağlık hizmetlerinde aksama olmaması sağlanır. Biyomedikal mühendislerinin klinik alanlarda yeterli istihdama sahip olmaması cihaz yönetimlerini de kesintiye uğratır (24). Tıbbi cihaz çeşitliliğinin fazla olması, cihazların ülkemizde ithal edilmesi ve yeterli personel olmaması yeni çözüm arayışlarını doğurmuştur.

2.4. TIBBİ CİHAZ ENVANTER YÖNETİMİ

Dünya Sağlık Örgütüne göre envanter, bir kurumun sahip olduğu varlıkların ayrıntılı ve maddelenmiş listesidir (25). Envanterin işlevsel olabilmesi için her bir varlığın mevcut durumunu yansıtması ve düzenli aralıklarla güncellenmesi gerekir. Envanter,

işletmelere finansal açıdan kılavuzluk eder ve bütçe kontrolü için bir rehber olur. Ülkelerdeki sağlık sisteminin yapılanmasına göre tıbbi envanter yapılanması değişkenlik gösterebilir. Sağlık sisteminin sunulduğu yere göre de envanterlerde değişiklik olabilir. Örneğin daha kırsal ve lokal bölgelerde kullanılan tıbbi cihaz çeşidi az olabilir ve bundan dolayı envanterler daha az güncelleniyor olabilir. Yüksek seviyede özelleşmiş sağlık kurumlarında birçok tıbbi cihaz bulunur, bu da tıbbi envanterlerin düzenli olarak güncellenmesini gerekli kılar.

Tıbbi cihaz envanteri, diğer envanterlerden farklı olarak bir tıbbi cihaza ait tüm bilgilerin detaylı olarak tanımlandığı listelerdir. Cihazın ismi, seri numarası, hastane içindeki konumu, markası ve modeli gibi bilgiler burada yer almaktadır. Envantere kaydedilmiş her bir cihaz için etiket oluşturulur ve cihaz üzerine yapıştırılarak cihaz kimlik tanımlaması damgalanmış olur (5).

Cihaz envanter bilgisi, cihaza ait tüm yaşam sürecini görünür kılar. Cihazın arıza durumu, problemin çözümü ve hurdaya ayrılana kadarki bilgiler burada kayıtlıdır. Cihaz problemlerinde bu bilgiler kılavuz niteliği görür (5).

Cihazların sayıca ve çeşit olarak fazla olması tedarik zincirini de karmaşıklaştırmıştır. Cihaz eksikliği, yanlış cihaz talepleri sağlık hizmetinin sunumunda sorunlar oluşturur. Güncellenmeyen tıbbi cihaz envanterleri yanlış satın alımlara, hatalı stok yönetimine, cihaz takiplerinin zorlaşmasına neden olur. Tüm bunlar cihazların atıl ve yetersiz kalmasına neden olur (5).

Sağlık sektöründe ürün çokluğu, ayrı stok ve hizmet yönetimi gerektirir. Bu nedenle envanter yönetimini destekleyen iyileştirici uygulamalar elzemdir. İyileştirilmiş cihaz envanteri yönetimi ile gerekli kaynaklar hazır durumda bulundurulur, hasta ihtiyaçları zamanında ve eksiksiz karşılanır (26).

2.5. ÇALIŞMA KAPSAMINDA İNCELENEN TIBBİ CİHAZLAR

Bu çalışma kapsamında görsel olarak birbirine benzeyen beş farklı tıbbi cihaz incelenecektir. Çalışmada hasta başı monitörü, fetal monitör, ventilasyon cihazı, EKG ve anestezi cihazı yapay zekâ algoritmalarıyla sınıflandırılacaktır.

2.5.1. Anestezi Cihazı

Tıbbi girişimlerin artması, hastalarda ağrısız ve konforlu süreç talebini doğurmuştur. Bu amaçla üretilen anestezi cihazı hastalarda ağrısız girişimin başlatılması ve sürdürülmesini sağlamaktadır. Cihaz, doktor eşliğinde hastaya kontrollü şekilde medikal gaz verir. Hastada yapay solunumu mümkün kılar ve monitorize edilmiş olan hastanın vital bulgularını takip etmeyi sağlar. Anestezi cihazları markaya göre değişiklik gösterse de temel olarak gaz sistemleri, manometre, akımölçer, buharlaştırıcı, solunum devreleri, ventilatör ve monitörden oluşur (27).



Şekil 2.1: Anestezi cihazı

Şekil 2.1'de anestezi cihazına ait bir görsel bulunmaktadır. Cihazın bilgisayar ve elektronik sistemle bütünleşik halde olduğu görülmektedir.

2.5.2. Hasta Başı Monitörü

Hasta başı monitörleri hastaya dair yaşamsal fonksiyonların gerçek zamanlı izlenmesini sağlar. Hastadaki kalp atım hızı, kandaki oksijenlenme seviyesi, kalbin elektriksel aktivitesi ve tansiyon değerlerini gösterir. Hasta başı monitörleri kliniklerde özellikle de yatan hastaların olduğu servislerde hastaya dair anlık sağlık verilerinin alınmasını mümkün kılar. Hastanın güncel sağlık verisini paylaşan bu cihazlar, bazı durumlarda hasta pozisyonundaki değişimlerden dolayı ölçümde sapmalara neden olarak hatalı bilgiler sunabilmektedir. Bu tür vaka senaryolarında, hastada olumsuz bir durum geliştiği düşünüldüğünde monitörlerdeki alarm sistemleri aktive olabilmektedir. Klinik

işleyişin aksamaması, hastaya dair doğru anamnez ve değerlendirmenin alınabilmesi için cihaz veya hasta bazlı değişimlere dikkat edilmeli, hasta bazlı fizyolojik parametreler göz önünde bulundurulmalıdır (28).



Şekil 2.2: Hasta başı monitörü

Şekil 2.2'de hasta başı monitörüne ait bir görsel bulunmaktadır. Cihaz ekranında hastanın vital bulgularına dair sayısal değerler bulunmaktadır.

2.5.3. Ventilasyon Cihazı

Akciğerler vücudumuzdaki karbondioksit ve oksijen değişimini sağlayan önemli organlardandır. Vücudumuz bu işlevi tam olarak yerine getiremediğinde ventilasyon cihazı kullanılır. Ventilasyon cihazı hayatta kalmanın temel gereksinimlerinden biri olan oksijenin vücudumuza transferini sağlar ve karbondioksitin uzaklaştırılmasını sağlar. Bu sayede temiz hava vücuda girerken kirli hava dış ortama transfer edilir. Sağlıklı bir insanda bağımsız ve spontane şekilde gerçekleşen bu işlem, hasta bireylerde ventilasyon cihazı ile yapay olarak sürdürülür. Hastanelerin özellikle yoğun bakım ünitelerinde sıklıkla kullanılır. Cihaz, bir tüp (endotrakeal tüp) ya da maske aracılığıyla hastaya bağlanır. Hastaya belirli bir hacimde ve basınçta hava verir. Cihazın yanlış kullanımında hastanın akciğerinde hasarlar oluşabilir. Cihaza ait çeşitli mod özelliklerinin olması tedavinin hatasız gerçekleşmesini sağlar (29).



Şekil 2.3: Ventilasyon cihazı

Şekil 2.3'te ventilasyon cihazına ait bir görsel bulunmaktadır. Cihazın temel olarak ana konsol, solunum devreleri ve hava kaynağı bağlantılarından oluştuğu görülmektedir.

2.5.4. Fetal Monitör

Fetal monitörler, anne karnındaki fetüsün kalp hızını ölçer ve bebeğin oksijensiz kalıp kalmadığını tespit eder. Obstetrik tanıda en çok kullanılan cihazlardandır. Yeni doğan ölümlerinin önlenmesi amacıyla 1980'lerden sonra aktif şekilde kullanılmaya başlanmıştır. İnternal ve eksternal olarak ikiye ayrılır. Eksternal monitörler, kardiyotokograf, ultrason probu, kontraksiyonları değerlendiren tokogram probu, elektronik gösterge ve verilerin yazıldığı kâğıttan oluşur. İnternal fetal monitörlerde ise intrauterin basınç kateteri ve fetusun baş kısmına yerleştirilerek fetal kalp sinyallerini ileten skalp elektrotlarından oluşur (30).

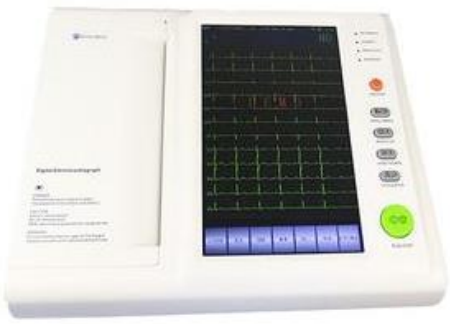


Şekil 2.4: Fetal monitör

Şekil 2.4’te fetal monitöre ait bir görsel bulunmaktadır. Cihaz ekranında bebeğin vital bulgularına dair sayısal değerler görülmektedir.

2.5.5. Kalp Akım Grafiği Cihazı

Kalp vücudumuza kan pompalayarak yaşamın devamını sağlar. Bu işlem gerçekleşirken kalbin atımı sırasında bazı elektriksel etkinlikler gerçekleşir. EKG, kalpteki bu elektriksel aktiviteleri EKG kâğıdına kaydeder. Elektriksel aktivitelerin izlenmesi için vücudun belli noktalarına elektrotlar yerleştirilir. Bunlar kalpteki elektriksel etkinlikleri yükseltir. EKG bu etkinlikleri yakalar ve kayıt altına alır. Her kalp atımı sırasında QRS ve T dalgaları oluşturur. Elektriksel gerilim değişiklikleri bu dalgalarda gözlenir. Cihaz, hekimin kâğıttaki QRS ve T dalgalarındaki elektriksel değişimleri ve karakteristik dalgalanmaları incelemesine imkân vererek tanıyı koymasına yardımcı olur. Cihaz temel olarak amplikatör, voltmetre, filtre ve kayıt ünitesinden oluşur (31).



Şekil 2.5: Kalp akım grafiği cihazı

Şekil 2.5’te EKG cihazına ait bir görsel bulunmaktadır. Cihaz ekranında hastaya dair QRS dalgalarının oluşturduğu çizgiler görülmektedir.

2.6. YAPAY ZEKÂNIN TANIMI

Yapay zekâ, insan zekâsının gerektirdiği karmaşık görevleri bilgisayar sistemleri aracılığıyla gerçekleştirmeyi hedefleyen bir bilişim alanıdır. Terim ilk kez 1956 yılında John McCarthy ve meslektaşları tarafından Dartmouth Konferansı’nda ortaya atılmıştır. Bu alan; akıl yürütme, problem çözme, doğal dil işleme, görsel algılama gibi konuları içerir (32).

Yapay zekânın temelinde, bilgisayar programlarının deneyimle performanslarını iyileştirmesi yatar. Özellikle makine öğrenimi ve onun bir alt dalı olan derin öğrenme, günümüzde yapay zekânın en önemli yöntemlerini oluşturur. Makine öğrenimi, büyük veri setlerindeki örüntüleri tespit ederek tahmin modelleri oluşturabilen algoritmaları kapsar. Derin öğrenme ise Yapay Sinir Ağları (YSA) kullanarak çok katmanlı öğrenme modelleri kurar. Böylece ham verilerdeki soyut özellikleri katmanlar halinde öğrenir ve karmaşık görevleri yüksek doğrulukla yerine getirebilir. Yapay zekâ sistemlerinin çalışma mekanizmaları, veriden beslenen istatistiksel modellerin kurulmasına ve deneyim arttıkça iyileşmesine dayanır (33).

Son yıllarda makinelerdeki hesaplama gücü ve büyük veri setlerine erişim artmıştır. Bu gelişmeler günümüzde yapay zekâ modellerinin daha başarılı sonuçlar vermesini sağlamıştır. Özellikle derin öğrenme algoritmaları, görüntü tanıma ve doğal dil işleme gibi zor problemler üzerinde yüksek başarılar elde etmiştir. Bununla birlikte, güncel yapay zekâ modellerinin kara kutu niteliği, yani karar süreçlerinin açıklanmasının zor olması, güvenilirlik ve etik gibi konuları da öne çıkarmıştır (34).

2.7. MEDİKAL ALANDA YAPAY ZEKÂ UYGULAMALARI

Sağlık sektörü, yapay zekâ uygulamalarının hızlı ilerleme kaydettiği alanlardan biridir. Son yıllarda yapılan çalışmaların neredeyse yarısına yakını tanı koyma amaçlı yapay zekâ uygulamalarına odaklanmıştır. Diğer yarısı da tedavi planlaması, prognoz tahmini gibi amaçlara yöneliktir (35).

2.7.1. Tanı Alanında Yapay Zekâ

Tıbbi tanı koyma süreci, yapay zekânın en çok uygulama alanı bulduğu sahalardan biridir. Yapay zekâ destekli tanı sistemleri; hastaların tıbbi görüntüleri, laboratuvar sonuçları veya EKG gibi sinyal verilerini analiz eder ve bu sayede hekimlere yardımcı olur. Bu sistemler, insan gözünün veya geleneksel yöntemlerin tespit etmekte zorlanabileceği karmaşık desenleri ortaya çıkarabilir, böylelikle tanıda hız ve doğruluk artışı sağlayabilir (36).

Mayo Klinik'te yapılan bir çalışma, normal bir EKG'den hastanın kalp pompalama fonksiyonunun zayıf olup olmadığını tahmin edebilen bir yapay zekâ modeli geliştirmiştir (37). Bu model, hiçbir belirti vermeyen hastalarda dahi EKG sinyallerindeki ince ipuçlarını yakalayarak erken dönemde müdahale şansı yaratmıştır. Bazı yapay zekâ

uygulamaları hasta tarafından doldurulan semptom sorgularını değerlendirip, ön tanı tahminleri yaparak (örneğin, triyaj amaçlı sohbet botları) hastaların doğru uzmana yönlendirilmesinde rol oynayabilmektedir (38).

2.7.2. Tedavi Planlamasında Yapay Zekâ

Hastalıklara yönelik genel tedavi protokolleri bazı kişiler için uygun olmayabilir. Her bireyin birbirinden farklı olduğunu savunan kişiselleştirilmiş tıp uygulamaları günümüzde daha da önem kazanmıştır.

Kişiselleştirilmiş tıp alanında yapay zekâ kullanımı, her bir hastaya en uygun tedavinin belirlenmesi için büyük potansiyel sunmaktadır. Örneğin onkolojide, yapay zekâ algoritmaları ile hastadaki tümörün genetik profili analiz edilebilmektedir. Hastaya verilecek kemoterapi ilacının hastada yanıt verip vermeyeceği tahminlenebilmektedir. Wang ve arkadaşlarının oluşturduğu bir derleme makalesinde, yapay zekânın kanser tedavisinde hedefe yönelik ilaç geliştirmesi ve ilaç yanıtının öngörülmesine dair umut vadeden sonuçlar paylaşılmıştır (39). Bu tür uygulamalar, tedaviyi hastaya özel hale getirip gereksiz yan etkileri önlemede değerli birer araç olabilir.

Tedavi planlamasında yapay zekânın öne çıktığı bir diğer alan, radyasyon onkolojisi ve özellikle ışın tedavisi (radyoterapi) hazırlığıdır. Radyoterapi uygulamadan önce, hedef tümörün ve çevresindeki sağlıklı organların görüntüleme ile belirlenip kontur çizilmesi (segmentasyon) gerekir. Bu zahmetli işlem geleneksel olarak radyolog ve radyasyon onkoloğu tarafından elle yapılır ve bir hasta için genellikle bir saat kadar zaman alabilir. Güncel yapay zekâ destekli sistemler ise bu segmentasyon işlemini otomatikleştirerek büyük bir zaman kazanımı sağlamaktadır. Kibudde ve arkadaşlarının yaptığı bir çalışmada, yapay zekâ tabanlı bir yazılımın baş, boyun ve prostat kanseri hastalarında kritik organları ortalama 2 dakikada başarılı şekilde konturlayabildiği belirtilmiştir. Çalışmada, bu işlemin uzmanlarca manuel yapılmasının 57–84 dakika sürdüğü rapor edilmiştir (40).

İlaç keşfi ve geliştirme süreçleri de yapay zekâ ile hız kazanmıştır. Derin öğrenme modelleri ile milyarlarca molekül içinden belirli bir hastalığa etki edebilecek yapıdaki aday moleküller kısa sürede taranabilmektedir. Özellikle 2021 yılında geliştirilen AlphaFold gibi yapay zekâ sistemleri, proteinlerin 3 boyutlu yapısını doğru olarak tahmin

edebilmiştir. Bu gelişmeler, yeni ilaç bileşiklerin tasarımına ciddi anlamda yardımcı olmuştur (41).

2.7.3. Tıbbi Görüntülemede Yapay Zekâ

Tıbbi görüntüleme, yapay zekâ uygulamalarının en parlak sonuçlar verdiği alanlardan biridir. Literatürde yapay zekânın görüntüleme yoluyla tanı konusundaki başarısı özellikle dikkat çekicidir. Derin öğrenme modelleri, radyoloji ve patoloji gibi görüntü ağırlıklı disiplinlerde, insan uzmanlarla kıyaslanabilir doğrulukta tanı koyabilmektedir (42).

Radyoloji uzmanları her gün yüzlerce görüntüyü (röntgen, bilgisayarlı tomografi görüntüleri, ultrason vb.) inceleyerek tanı koymaya çalışırken yapay zekâ, bu görüntülerin analizinde güçlü bir yardımcı araç olarak öne çıkmaktadır (43).

Nature dergisinde yayımlanan bir çalışmada, tarama mamografilerinde derin öğrenme algoritmalarının insan radyologlara kıyasla daha yüksek doğrulukta kanser tespiti yaptığı rapor edilmiştir. Bu sistem, özellikle yalancı pozitif (hatalı şekilde kanser var diye işaretlenen) bulguları %5'e varan oranda azaltmıştır. Yalancı negatif (gözden kaçan kanser) vakalarında ise bu oran %2–3 oranındadır (44).

Dijital patoloji alanı da yapay zekâ devriminin etkisinin hissedildiği alanlardandır. Mikroskop altında incelenen doku örnekleri, günümüzde yüksek çözünürlüklü tarayıcılar ile sayısallaştırılabilmektedir. Bu sayısal görüntüler yapay zekâ algoritmaları tarafından analiz edilebilmektedir. Esteva ve arkadaşları yaptıkları bir çalışmada, cilt lezyonlarının sınıflandırılması için bir derin öğrenme modeli geliştirmiştir ve bu model melanom teşhisini hekimlerle aynı doğrulukta yapmayı başarmıştır (45). Özellikle kanser tanısında, derin öğrenme modelleri hücresel düzeydeki morfolojik değişimleri fark edebilmektedir. Böylece yapay zekâ tanısal doğrulukta ikinci bir göz olarak görev yapmaktadır.

Yapay zekâ, tıbbi görüntülemede sadece tanı koyma amacıyla değil, görüntülerin oluşturulması ve işlenmesi alanlarında da yenilikler getirmektedir. Yapay zekâ destekli görüntü işleme uygulamaları, gürültülü veya bulanık görüntüleri düzeltebilmektedir. Bilgisayarlı tomografi işleminde yapay zekâ filtreleri kullanılarak daha düşük radyasyon dozuyla yüksek kaliteli görüntüler elde etmek mümkün olmuştur. Bu gelişmeler, hastaya daha az zarar vererek (daha düşük radyasyon, daha kısa tarama süresi) tanı koyabilmeye olanak tanımaktadır (42).

İnsan değerlendirmeleri; yorgunluk, dikkat dalgalanmaları veya deneyim farkları nedeniyle değişkenlik gösterebilir. Yapay zekâ uygulamaları bu gibi sorunlara yardımcı olmakta ve tanı kalitesini arttırarak daha doğru tedavi planlamaları yapmaya olanak sağlamaktadır.

2.8. MAKİNE ÖĞRENİMİNİN TANIMI

Makine öğrenimi, yapay zekânın bir alt alanıdır. Bilgisayarların açıkça programlanmadan verilerden öğrenerek performanslarını iyileştirmesini sağlar. Makine öğrenimi algoritmaları ile makineler verilerdeki örüntüleri keşfedebilir ve modele yönelik tahminler yapabilir (10). Günümüzde makine öğrenimi, görüntü tanımadan konuşma algılamaya, doğal dil işleme ve robotik kontrolüne kadar hemen her alt alanda büyük ilerlemeler kaydetmiştir (33). Bu ilerlemeler sayesinde makine öğrenimi günümüzde pek çok sektörde kritik bir rol oynamaktadır. Sağlık hizmetleri de bunlardan biridir. Stokes ve arkadaşlarının 2020 yılında geliştirdikleri makine öğrenimi modeli, yeni bir antibiyotik molekülü keşfetmiştir. Geliştirilen makine öğrenimi modeli milyonlarca aday molekülü taramıştır ve günümüzde antibiyotiklere dirençli bakterileri öldürebilecek güçlü bir bileşiği tanımlamıştır. Halicin adlı bu yeni bileşik, makine öğrenimi tarafından keşfedilen ilk antibiyotik olmuştur ve küresel bir sorun olan antibiyotiğe dirençli bakteriler konusuna bir çözüm ışığı olmuştur. Bu çalışma farklı ilaç keşif projelerini de hızlandırmıştır (46). Makine öğrenimi algoritmaları, sağlık dışında finansal analiz, otonom araçlar ve endüstriyel üretim gibi birçok alana destek olmuştur.

2.9. TEMEL MAKİNE ÖĞRENİMİ YÖNTEMLERİ

Makine öğrenimi teknikleri temel olarak denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana kategoride incelenir (47).

Denetimli öğrenmede algoritmalar, etiketlenmiş verilerle çalışır; veri üzerinden eğitim alarak tahminler yapmayı öğrenir. Denetimli öğrenme problemleri sınıflandırma ve regresyona odaklanır. Bu alandaki temel algoritmalara lojistik regresyon, karar ağaçları ve SVM örnek olarak verilebilir (48).

Denetimsiz öğrenmede ise verilerdeki gizli yapıları keşfetmek hedeflenir. Veriler üzerinde etiket olmadan çalışılır. Kümeleme ve boyut indirgeme bu alandaki en temel uygulamalardır. Kümelemede benzer veriler gruplandırılır. Boyut indirgemede ise verideki önemli özellikler çıkarılır (49).

Son öğrenme yöntemlerinden pekiştirmeli öğrenme ise deneme-yanılma yoluyla öğrenme üzerine kuruludur. Sisteme ödül ceza yöntemi uygulanır ve sistem almış olduğu geri bildirimlerle öğrenmeyi gerçekleştirir. Oyun oynayan bir yapay zekânın ödül kazanacak hamleleri öğrenmesi bu öğrenme yöntemine örnektir (50).

2.10. MAKİNE ÖĞRENİMİ ALGORİTMALARI

Makine öğrenimi algoritmaları, verinin niteliğine ve çözülmek istenen göreve göre sınıflandırılır. Bazı algoritmalar veri temelli tahmin yapmaya yararken bazıları verideki yapısal benzerlikleri bulmaya odaklanabilir. Her algoritmanın öğrenme şekli farklıdır. Bazıları örnekleri sınıflandırırken bazıları gruplar oluşturur. Algoritmalar karmaşık gibi görünse de temel amaç veriden anlam çıkarmaktır. Verinin boyutu arttıkça seçilen algoritmanın önemi daha da artar çünkü her birinin kendi içinde avantaj ve dezavantajları bulunmaktadır. Bunlardan en bilinenleri: SVM, karar ağaçları, rastgele orman, Naive Bayes, lojistik regresyon ve KNN algoritmalarıdır.

2.11. ÖZELLİK SEÇİMİ

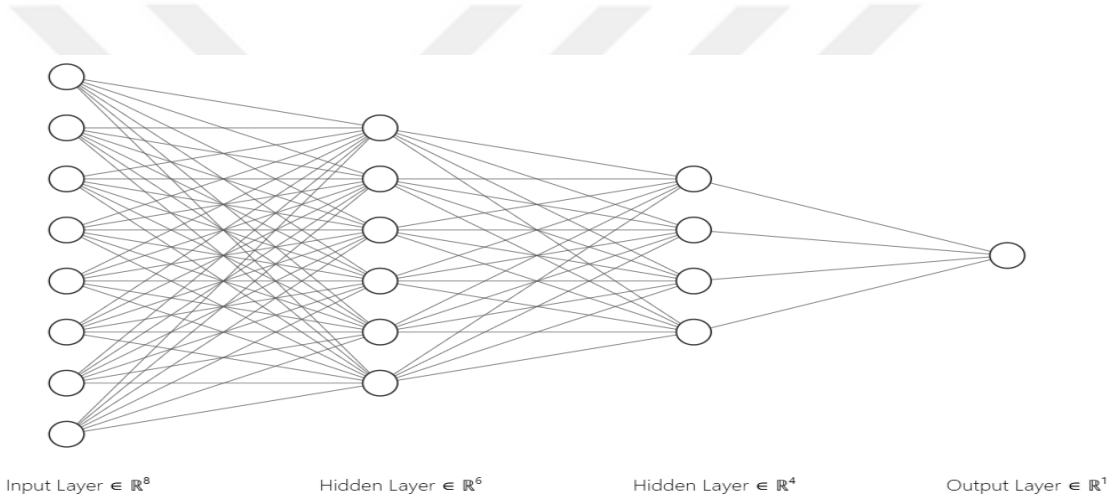
Makine öğrenmesinde veriler genellikle çok sayıda özellikle gelir. Ama bu özelliklerin hepsi faydalı değildir. Bazı özellikler gereksiz ya da birbirini tekrar ediyor olabilir. Bu yüzden modelin performansını arttırmak için en etkili olanları seçmek gerekir. Özellik seçimi, genellikle istatistiksel değerler, model çıktıları ya da bilgi teorisi temelli ölçümler ile yapılır (51).

Özellik seçiminde sarma, filtre ve gömülü yöntemler olmak üzere üç ana yaklaşım vardır. Sarma yönteminde seçilen özelliklerin model üzerindeki etkisine deneme yoluyla karar verilir. Recursive Feature Elimination (RFE) sarma yöntemine bir örnektir. Gömülü yöntemde özellik seçimi model eğitimi sırasında otomatik olarak yapılır. Lasso ve karar ağaçları algoritması gömülü yönteme örnektir. Son olarak filtre yöntemi bulunmaktadır. Burada veriye bağlı olarak bağımsız şekilde özellik seçimi yapılır. fMRMR uygulaması bu yaklaşıma örnektir (52).

2.12. DERİN ÖĞRENME

Derin öğrenme, YSA tekniklerini kullanan çok katmanlı hesaplama modelleridir. Beynimizdeki sinir hücrelerine nöron adı verilir. Beyinde bulunan birçok nöron kendi aralarında iletişim ağı oluşturarak verinin bir bölgeden diğerine aktarımını sağlarlar.

Bilginin aktarımı nöronlardaki elektriksel aktivitelerle gerçekleştirilir. Bu sayede düşünme, davranış ve eyleme geçme aktiviteleri gerçekleşmiş olur. Doğadaki birçok unsurun teknolojiye esin kaynağı oluşturması gibi insan zihninin düşünce yapısı da YSA'nın esin kaynağı olmuştur. Biyolojik bir ilham kaynağı olan bu nöronlar makineler üzerinde modellenmek istenmiştir. Derin terimi, girdiden çıktıya doğru birden çok gizli katmanın bulunduğu ağ yapılarını ifade eder. Her bir katman bir öncekinin çıktısını alır. Soyut ve karmaşık temsil seviyeleri öğrenir. Hiyerarşik bir öğrenme gerçekleştirir. Alt seviyelerde basit özellikler vardır. Üst seviyelere çıkıldıkça ise daha karmaşık yapılar temsil edilir. Bu yaklaşım temsil öğrenimi olarak da bilinir ve veriden otomatik olarak öz nitelikler çıkarmayı sağlar (11,53).



Şekil 2.6: Yapay sinir ağları mimarisi

Şekil 2.6'da sekiz giriş değeri alabilen dört katmandan oluşan bir sinir ağındaki girdi, katman ve nöron yapıları gösterilerek genel ağ yapısı mimarisi ortaya konmuştur.

2.13. YAPAY SİNİR AĞLARININ ÇALIŞMA PRENSİBİ

Biyolojik nöronlar gelen uyarana göre bir karar alır. Eğer uyaran belli bir eşik değerini geçerse nöron buna sinyal iletimi oluşturarak bir yanıt verir. Makineler üzerinde de benzer yöntem geliştirilmiştir. Basit bir nöron yapısı incelendiğinde bilginin girdi katmanında nöral ağa ulaşmak için belli bir ağırlık bulunur. Girdi katmanındaki değer ilgili ağırlıkla çarpılır. Çarpılmış olan bu ağırlıklar toplanır. Böylece nöron üzerinde birikmiş bir nöral yük oluşur. Eğer bu yük belirlenen eşik değerini aşarsa nöron üzerinde sinyal ateşlemesi gerçekleşir ve bilgi transferi diğer nöronlara geçer. Bu işlemin

gerçekleşmesinde aktivasyon fonksiyonu kullanılır. Aktivasyon fonksiyonu, girdi katmanından gelen bilgileri döndürerek anlamlı bir yanıt oluşturmak için yapılmış bir matematiksel fonksiyondur (11).

Modele göre farklı matematiksel fonksiyonlar (aktivasyon fonksiyonları) kullanılarak çıkan sonucun nasıl yansıma yapacağı, ateşlenmenin olup olmayacağı belirlenmiş olur. Nöron buna göre aktive olmuş olur (54).

2.14. YAPAY SİNİR AĞININ ÖĞRENME SÜRECİ

Girdi katmanında verilen ham veri ve bunun sonucunda makine tarafından oluşturulan çıktı gerçek sonucu yansıtmayabilir. Bu doğru bir öğrenme olmadığını gösterir. Nöral ağın gerçek değerden ne miktarda hatalı ölçüm yaptığı kayıp fonksiyonu ile bulunur. Gerçek sonuçtan ne kadar sapılırsa kayıp fonksiyonu da o kadar artar. Öğrenmedeki temel hedef her zaman en az hatayı yapmaktır. Öğrenme sürecinde model, her bir eğitim örneği için bir kayıp (hata) fonksiyonu değerini hesaplar ve bu hatayı minimize edecek şekilde ağ parametrelerini (ağırlıklar ve biaslar) günceller. Bunu yaparken modele geri yayılımlı öğrenme uygulanır. Geri yayılımlı öğrenmede amaç, modelin yanlış çıktıya ulaşmasına neden olan çarpan etkilerinin azaltılmasıdır. Ağırlık çarpanlarının değiştirilmesi modelin doğru çıktı üretmesini sağlar ve kayıp fonksiyonu değerini de düşürür. Çarpan güncellemelerinde modeldeki kayıp fonksiyonu ve öğrenme oranı göz önünde bulundurulur (55).

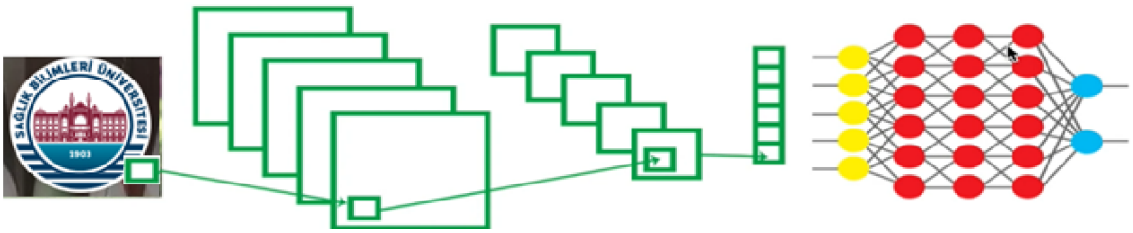
Ağdaki öğrenme katsayısı sıfıra yaklaştıkça öğrenme yavaşlar, bire yaklaştıkça hızlanır fakat hızlı öğrenme beraberinde çabuk unutmayı da getirir. Öğrenme oranının küçük olması bir noktadan sonra gerçek çıktıya yaklaşıldığını gösterir. Öğrenme oranının yüksek olması, öğrenme hızında artışı hızlandırırken bir süre sonra olumsuz etki ederek yanlış çıktıların oluşmasına neden olabilir. Bu nedenle yüksek değerde bir öğrenim oranı her zaman iyi bir çıktı, yani doğru bir öğrenme olduğu anlamına gelmez (56).

Eğitim genellikle birçok devir (tüm veri kümesinin modelden geçirilmesi) boyunca tekrar edilir. Model her yinelemede hatayı biraz daha azaltmayı öğrenir. Modelin eğitim sürecini etkileyen ayarlara hiperparametre denir. Bu ayarların değiştirilmesiyle gerçek çıktıya yaklaşılır. Benzer şekilde optimizasyon algoritmaları da modelin doğru çıktıya ulaşmasını kolaylaştırır. Stokastik gradyan alçalışı ya da Adam gibi optimizasyon

algoritmaları, çarpanların hangi ölçüde güncelleneceğine yardımcı olur ve doğru öğrenmeye destek olur (57).

2.15. EVRİŞİMSEL SİNİR AĞLARININ TANIMI

Derin öğrenme modellerinin alt kümesinden olan ESA, literatürde konvolüsyonel sinir ağları olarak da bilinmektedir. ESA, çok katmanlı algılayıcılardandır. Öğrenebilen ağırlıklandırılmış nöral ağlardan oluşmuştur. İlk kez 1998 yılında Yan LeCun tarafından tanıtılmıştır (12). Klasik YSA'nın yetersiz kaldığı noktalarda çözüm yolu olarak geliştirilmiştir. Artan veri yoğunluğu ve bilişim alanındaki gelişmelerin hızla artması ESA'nın da gelişimini hızlandırmıştır. ESA, bilgisayarlardaki görüntü işlemlerinde sıklıkla kullanılır. Öznitelik çıkarımı yapar. Resimler arasındaki farkları tespit edebilen bir nöral ağ yöntemidir. ESA ile ilişkili birçok derin ağ mimarisi bulunur (58). ESA yüksek çözünürlüklü görüntü hesaplamalarında zorlanabilmektedir. Bundan dolayı görüntü belli bir formata getirilmelidir. Sistem sırasında parametre sayılarındaki artış gradyanların kaybolmasına neden olabilir. Bu da görüntünün net olarak ayırt edilememesine neden olur (59).



Şekil 2.7: Evrişimsel sinir ağları çalışma prensibi

Şekil 2.7'de ESA'nın işleyişine dair bir görsel bulunmaktadır. ESA, görüntünün her bir bölgesini ayrıntılı şekilde inceleyerek görselin temel özelliklerini belirlemeye çalışmaktadır.

2.16. TEMEL EVRİŞİMSEL SİNİR AĞLARI MİMARİLERİ

Temel ESA mimarilerinin evrişim, havuzlama, düzleştirme gibi yapı taşları benzerlik göstermekle birlikte farklı oldukları noktalar da vardır. Bazı mimariler daha sade ve az katmanlıyken bazıları daha derin olabilir. Kullanılan filtrenin boyutu ve bunun uygulanma yöntemi değişebilir. Mimariler arasındaki parametre sayısı ya da hesaplama

yükü farklılık gösterebilir. Bazı mimariler çok yüksek doğruluk verebilir ama hızlı çalışmayabilir. Hedefe göre doğru mimari seçmek bu açıdan önemlidir. VGG16, ResNet-50, GoogleNet, AlexNet en çok bilinen mimarilerdendir (12).

2.17. TRANSFER ÖĞRENME

Transfer öğrenme, bir makine öğrenimi modelinin bir görevde edindiği bilgi ve deneyimi ilgili bir başka göreve aktarmasıdır. Bu sayede hedef görevdeki performansı iyileştirmek hedeflenir. Özellikle ESA'da sıklıkla kullanılır. Büyük bir veri kümesinde (örneğin, ImageNet) eğitilmiş olan bir modelin çıktıları çalışılmakta olan modele transfer edilir (60). Bu yaklaşım, sıfırdan eğitime kıyasla eğitim süresini kısaltır, büyük ölçüde veri ihtiyacını azaltır ve modelin başlangıç performansını yüksek tutar. Transfer öğrenme, insan uzmanlığına dayalı özellik çıkarım ihtiyacını ortadan kaldırır ve daha anlamlı, ifade gücü yüksek görsel özellikler elde edilmesini sağlar (61).

2.18. PERFORMANS METRİKLERİ

Yapay zekâ modellerinden elde edilen tahmin sonuçlarının değerlendirilmesi için performans metriklerinden yararlanılmıştır. Performans metrikleri modelin tahmin sonuçlarından elde edilen doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerlerine bağlı olarak elde edilir. Elde edilen doğru pozitif tahmin sonuçları test setinde pozitif olan ve model tarafından da pozitif olarak tahmin edilen verilerdir. Elde edilen doğru negatif tahmin sonuçları ise test setinde negatif olan ve model tarafından da negatif olarak tahmin edilen verilerdir. Test veri setinde gerçekte negatif olan ama model tarafından yanlış şekilde pozitif tahmin edilen veriler yanlış pozitif olarak kabul edilir. Test veri setinde gerçekte pozitif olan ama model tarafından yanlış şekilde negatif olarak tahmin edilen veriler yanlış negatif olarak kabul edilir. Bu tez çalışmasında doğruluk, kesinlik, duyarlılık ve F1 skor değerlerinden yararlanılmıştır (62).

3. GEREÇ VE YÖNTEM

Bu bölümde tıbbi cihaz envanter doğruluğunun optimizasyonunda kullanılan veri seti hakkında bilgi verilmiştir. Sonrasında ise kullanılan veri setinin önerilen yöntem ile kullanıldığında yüksek performans vermesini sağlamak amacıyla yapılan ön işleme adımlarından bahsedilmiştir. Bölüm sonunda ise önerilen yöntemin adımları açıklanmıştır.

3.1. GEREÇ

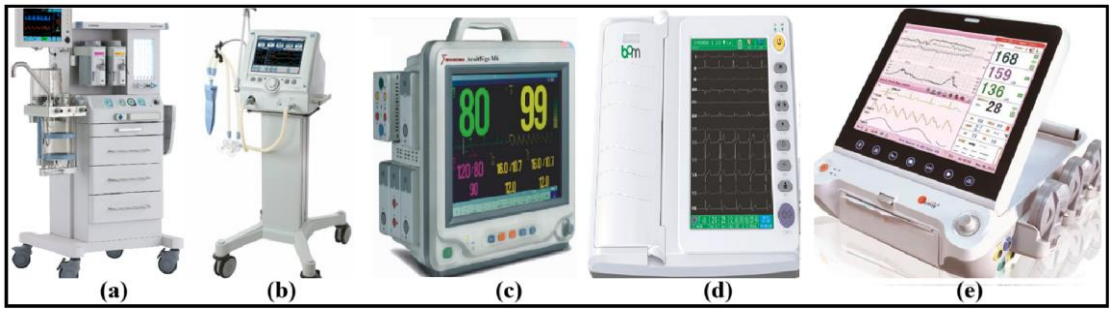
3.1.1. Veri Seti

Bu tez çalışmasında 'Medikal Cihaz 5' veri seti kullanılmıştır. Medikal Cihaz 5 veri seti, biyomedikal çalışmaları yapay zekâ ile kolaylaştırmak amacıyla hazırlanmış ve kullanıcıların açık erişimine sunulmuştur. Veri seti, Kaggle veri bilimi platformundan temin edilmiştir. Medikal Cihaz 5 veri seti; anestezi, ventilatör, hasta başı monitörü, fetal monitör ve EKG cihazlarına ait görüntü sınıflarını içermektedir. Beş sınıftan oluşan veri setinde toplam 947 adet cihaz görüntüsü mevcuttur. Veri setinde yer alan tıbbi cihaz görüntüleri internet kaynaklarından elde edilmiş ve doğrulama sürecine tabi tutulmuştur. Bu sayede görüntülerin ait oldukları sınıflar en doğru biçimde belirlenmiştir. Medikal Cihaz 5 veri setine https://www.kaggle.com/datasets/nedimmuzoglu/medical-device-5-dataset/ adresinden ulaşılabilmektedir.

Tablo 3.1: Medikal Cihaz 5 veri seti örnek sayılarının dağılımı

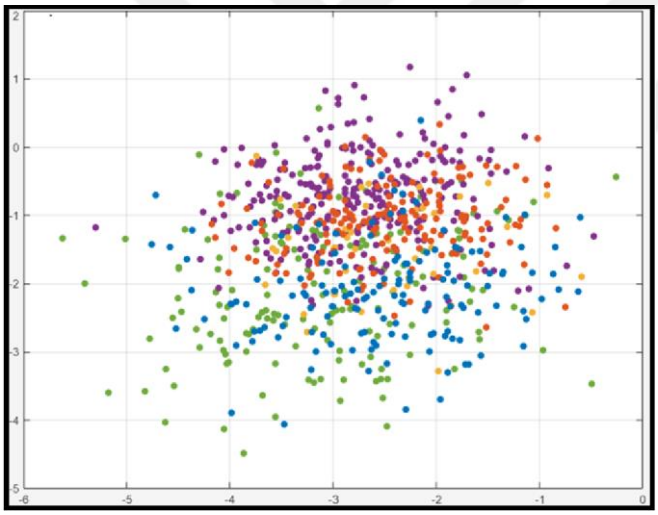
Cihaz Türleri	Eğitim Veri Seti	Doğrulama Veri Seti	Test Veri Seti	Tıbbi Cihaz Sayısı
Anestezi	128	19	37	184
Ventilatör	134	20	38	192
Hastabaşı Monitör	220	31	64	315
EKG	141	21	40	202
Fetal Monitör	37	7	10	54

Bu tez çalışması için veri seti; eğitim, validasyon ve test veri kümelerine ayrılmış olup veri setindeki ilgili cihaz sayılarına ait bilgiler Tablo 3.1'de verilmiştir.



Şekil 3.1: Medikal Cihaz 5 veri seti her bir cihaz türüne ait örnekler. (a) Anestezi cihazı, (b) Ventilatör, (c) Hasta başı monitör (d) Kalp akım grafiği cihazı, (e) Fetal monitör

Medikal Cihaz 5 veri setinde bulunan her bir sınıfa ait örnek görüntüler Şekil 3.1'de verilmiştir.



Şekil 3.2: Medikal Cihaz 5 veri setindeki örneklerin iki boyutlu dağılımı

Şekil 3.2'de ise veri kümesindeki örneklerin iki boyutlu dağılımı gösterilmektedir. Noktaların renklerle temsil edilmesi, farklı sınıfları veya kümeleri ifade etmektedir. Görselden de anlaşılacağı üzere, sınıflar arasında belirli ölçüde örtüşme ve yoğunluk farklılıkları bulunmaktadır.

Veri setindeki cihaz sınıflarının sayı dağılımı incelendiğinde, sınıflar arasında belirgin bir dengesizlik olduğu görülmektedir. Yapay zekâ modelleri, öğrenme süreci boyunca giriş verilerine dayalı olarak ağırlıklar oluşturur. Bu süreçte, örnek sayısı fazla olan sınıflar modele daha fazla katkı sağladığı için öğrenilen ağırlıklar bu sınıflar lehine

şekillenme eğilimindedir. Ancak modelin genel başarısının artırılabilmesi için sınıf dengesizliğinin neden olduğu bu tür ağırlık kaymalarının önlenmesi gerekmektedir. Sınıf dengesizliği içeren veri kümelerinde, modelin belirli sınıflara karşı ön yargılı öğrenmesini engellemek amacıyla başvurulan en etkili yöntemlerden biri, görüntü artırma teknikleridir.

Tablo 3.2: Görüntü artırma teknikleri sonrasında Medikal Cihaz 5 veri sayıları

Cihaz Türleri	Eğitim Seti	Veri Artırma	Veri Artırılmış Eğitim Seti
Anestezi	128	92	220
Ventilatör	134	86	220
Hastabaşı Monitör	220	-	220
EKG	141	79	220
Fetal Monitör	37	183	220

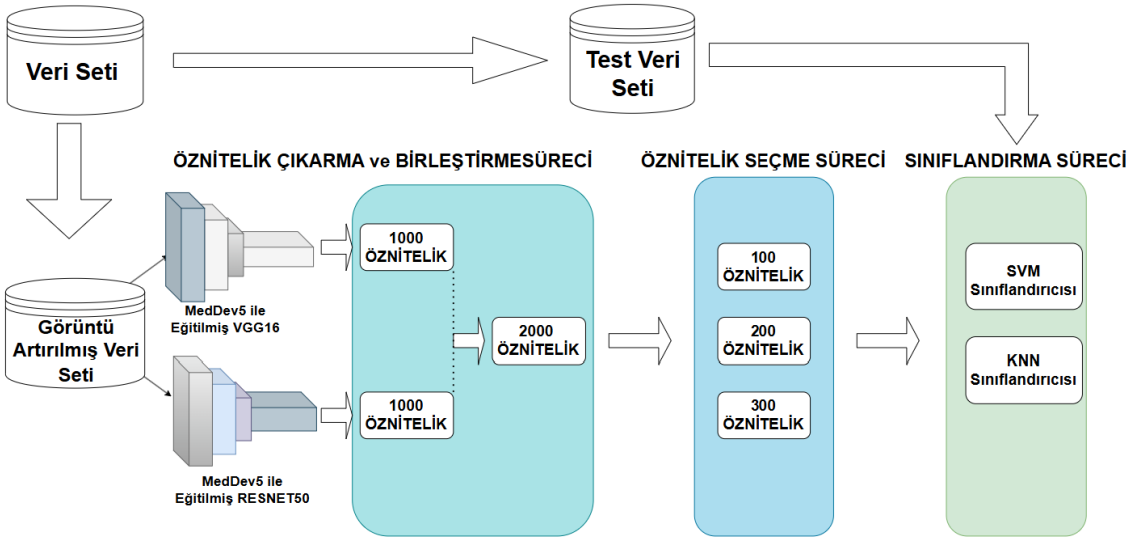
Tablo 3.2'de, görüntü artırma teknikleri kullanılarak düşük örnek sayısına sahip sınıfların verilerinin artırıldığı görülmektedir. Bu yöntem sayesinde tüm sınıflardaki örnek sayısı eşitlenmiştir ve her sınıfın örnek sayısı, veri setinde en fazla örneğe sahip sınıfın seviyesine çıkarılmıştır.

3.1.2. Tez Çalışması Esnasında Kullanılan Programlar

Bu tez çalışmasında görüntü işleme teknikleri ve yapay zekâ algoritmaları kullanılırken Keras Api üzerinde Python 3.9 ve Matlab2023b versiyonları kullanılmıştır.

3.2. YÖNTEM

Bu tez çalışmasında, medikal cihazların yapay zekâ tabanlı algoritmalar aracılığıyla sınıflandırılması amaçlanmıştır. Ancak kullanılan Medikal Cihaz 5 veri seti, sınıflar arasında dengesiz örnek dağılımı içermektedir. Bu sorunun etkilerini azaltmak amacıyla görüntü artırma yöntemleri uygulanmıştır. Böylece, eğitim veri setindeki tüm sınıfların örnek sayıları, en fazla örneğe sahip sınıf temel alınarak dengelenmiştir. Bu tez çalışmasında önerilen model, görüntü artırma sürecinin ardından üç temel aşamadan oluşmaktadır: öznitelik çıkarımı, öznitelik seçimi ve sınıflandırmadan oluşmaktadır.



Şekil 3.3: Medikal cihaz sınıflandırma çalışmasına ait akış diyagramı

Şekil 3.3'te bu tez çalışmasının gerçekleştirilmesinde takip edilen akış diyagramı ve her bir adımda takip edilen yöntemler bulunmaktadır.

3.2.1. Görüntü Artırma Teknikleri

Veri artırma, mevcut veriler üzerinde çeşitli dönüşümler gerçekleştirilerek eğitim veri kümesinin örnek çeşitliliğinin yapay biçimde genişletilmesini sağlayan bir tekniktir. Bu yöntem, özellikle bilgisayarlı görü alanında sık kullanılır ve makine öğrenimi ile derin öğrenme modellerinin farklı veri çeşitlerine uyum sağlamasını ve daha dayanıklı hale gelmesini amaçlar. Görüntü artırma teknikleri, bir görüntüde tek tek uygulanabileceği gibi, birden fazla yöntem art arda kullanılarak da uygulanabilmektedir. Bu tez çalışmasında kullanılan veri artırma yöntemleri aşağıda açıklanmıştır.

3.2.1.1. Döndürme: Görüntülerin belirli açılarla (örneğin 90°, 180°) döndürülerek yeni veri örneklerinin elde edilmesidir. Özellikle derin öğrenme modellerinde konvolüsyonel filtreler görüntüyü lokal bölgeler halinde işler; dolayısıyla görüntülerin farklı açılardan sunulması, modelin daha çeşitli özellikleri öğrenmesini sağlar. Bu çeşitlilik, modelin aşırı uyum sağlamasını (overfitting) önlemeye ve genelleme yeteneğini artırmaya yardımcı olur.

3.2.1.2. Çevirme: Görüntüyü yatay veya dikey olarak ters çevirme işlemidir. Böylece model nesnelerin farklı yönlerdeki görüntülerini görerek daha çeşitli verilerle

eğitir. Görüntünün yatay çevrilmesiyle oluşan yeni görüntü soldan sağa doğru aynalanacaktır. Böylece model, sağdan sola ya da soldan sağa yönlendirilmiş nesneleri tanımada daha başarılı olabilir.

3.2.1.3. Yakınlaştırma: Görüntünün belirli oranlarda büyütülerek veya küçültülerek yeni veri örneklerinin oluşturulmasıdır. Derin öğrenme modellerinin, farklı ölçeklerdeki görüntülerle eğitilmesi, modelin nesneleri çeşitli boyutlarda tanıma yeteneğini geliştirir. Bu sayede model, gerçek dünyadaki ölçek değişikliklerine karşı daha dayanıklı olur ve aşırı uyum sağlama riski azalır.

3.2.1.4. Parlaklık ayarı: Görüntünün parlaklığının artırılması veya azaltılmasıyla yeni veri örneklerinin elde edilmesidir. Bu yöntem, modelin farklı aydınlatma koşullarına karşı daha dayanıklı hale gelmesini sağlayarak gerçek dünya ortamlarındaki ışık değişimlerine karşı genelleme kabiliyetini artırır ve böylece aşırı uyum sağlama olasılığı azalır.

3.2.1.5. Kontrast değişikliği: Görüntüde piksel düzeyindeki düşük ve yüksek yoğunluk değerleri arasındaki farkın artırılması veya azaltılmasıyla kontrastın ayarlanması, modelin farklı ışık dağılımlarına ve görsel çeşitliliğe sahip sahneleri daha iyi öğrenmesini sağlamaktadır.

3.2.2. Özniteliklerin Elde Edilmesi ve Birleştirilmesi

Görüntülerin şekil, renk, doku, kenar, köşe, desen gibi yapısal özellikleri modelin sınıflandırma sürecinde kullandığı temel bilgi parçacıklarıdır. Bu bilgi parçacıkları, görüntünün öznitelikleri olarak tanımlanır ve bu doğrultuda veri setleri, bir öznitelik uzayı olarak ifade edilebilir. Bu tez çalışmasında özniteliklerin elde edilmesi VGG16 ve ResNet-50 derin öğrenme modelleri yardımıyla sağlanmıştır. Bu modellerin son katmanlarından her bir görüntü için 1000 boyutlu öznitelik vektörleri çıkarılmıştır. Elde edilen öznitelikler birleştirilerek, görüntülerin daha yüksek doğrulukla sınıflandırılması amaçlanmıştır. Böylece veri setindeki her bir görüntü 2000 öznitelik ile temsil edilmiştir. Ancak özniteliklerin birleştirilmesi sonucunda, farklı modellerden elde edilen benzer veya tekrarlayan özniteliklerin bir araya gelmesi ya da sınıflandırma performansına katkı sağlamayan gereksiz özniteliklerin bulunması, öznitelik vektörünün gereksiz yere büyümesine neden olabilmektedir. Bu durum, sınıflandırma performansını olumsuz

etkileyebilir. Bu sebeple öznitelik seçme yöntemine ihtiyaç duyulmuştur. Bu tez çalışmasında kullanılan ESA modelleri aşağıda açıklanmıştır.

3.2.2.1. VGG16: 2014 yılında Oxford Üniversitesi Görsel Geometri Grubu tarafından geliştirilmiştir. 16 sayısı, modeldeki toplam katman sayısını temsil eder. Özellikle ImageNet gibi büyük veri setlerinde başarılıdır. Transfer öğrenme için çok uygundur. Tüm konvolüsyon filtreleri 3×3 boyutundadır. Parametre sayısı 138 milyondur. Aktivasyon fonksiyonu olarak ReLu'yu kullanır. Mimarisi basit ama derindir. Görüntü sınıflandırma, görüntü tabanlı öznitelik çıkarımı ve görsel benzerlik karşılaştırmaları gibi alanlarda kullanılır.

3.2.2.2. ResNet-50: 2015 yılında Microsoft Research tarafından geliştirilmiştir. Kelime anlamı olarak artık ağ anlamına gelir. 50 sayısı, ağda 50 tane katman olduğunu ifade eder. İç yapısında rezidüel bloklar bulunur. Diğer ağlara kıyasla en büyük yeniliği kaybolan gradyan sorununa yenilik getirmesidir. Böylelikle daha doğru öğrenme gerçekleştirir. Bunu yaparken atlamalı bağlantılar kullanır. Derin ağların eğitimini kolaylaştıran ilk mimaridir. Transfer öğrenmede en çok kullanılan modellerdendir. ImageNet 2015 yarışmasında birinci olmuştur. Bu tez çalışmasında ResNet-50'nin "fc1000" katmanından her bir görüntü için öznitelikler elde edilmiştir.

3.2.3. Öznitelik Seçim Süreci

Bu adımda, elde edilen 2000 öznitelik arasından en ayırt edici olanların seçilmesi ve sınıflandırma açısından gereksiz veya tekrarlı olanların elenmesi amacıyla bir öznitelik seçme süreci uygulanmıştır. Bu süreç sonucunda, en belirgin 100, 200 ve 300 öznitelik belirlenmiştir. Öznitelik seçim sürecinde fMRMR seçim algoritması kullanılmıştır.

3.2.3.1. Hızlı Minimum Fazlalık Maksimum Alaka Algoritması: Bir öznitelik seçim algoritmasıdır. Filtre tabanlı algoritmalar özniteliklerin önem derecesine göre sıralama yaparken aralarındaki korelasyonu dikkate almaz. Bu durum, gereksiz özniteliklerin öznitelik uzayında kalmaya devam etmesi ile sonuçlanır. Bu duruma çözüm olarak öznitelikler ile sınıf etiketleri arasında hızlı minimum fazlalık ve maksimum alaka sağlayan fMRMR seçim algoritması geliştirilmiştir. fMRMR algoritması, öznitelikler ile sınıf etiketleri ve diğer öznitelikler arasındaki benzerliği karşılıklı bilgi ile ölçer. Algoritma öncelikle öznitelikler arasındaki karşılıklı bilgiyi hesaplar. fMRMR, elde

edilen bu bilgiyi kullanarak öznitelikler ve sınıf etiketleri arasında maksimum ilişkiyi sağlayacak şekilde seçim işlemi yapar.

3.2.4. Sınıflandırma Süreci

Bu adımda Medikal Cihaz 5 veri setiden elde edilen en belirgin 100, 200 ve 300 öznitelik kullanılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma algoritması olarak ise SVM ve KNN algoritmaları kullanılmıştır.

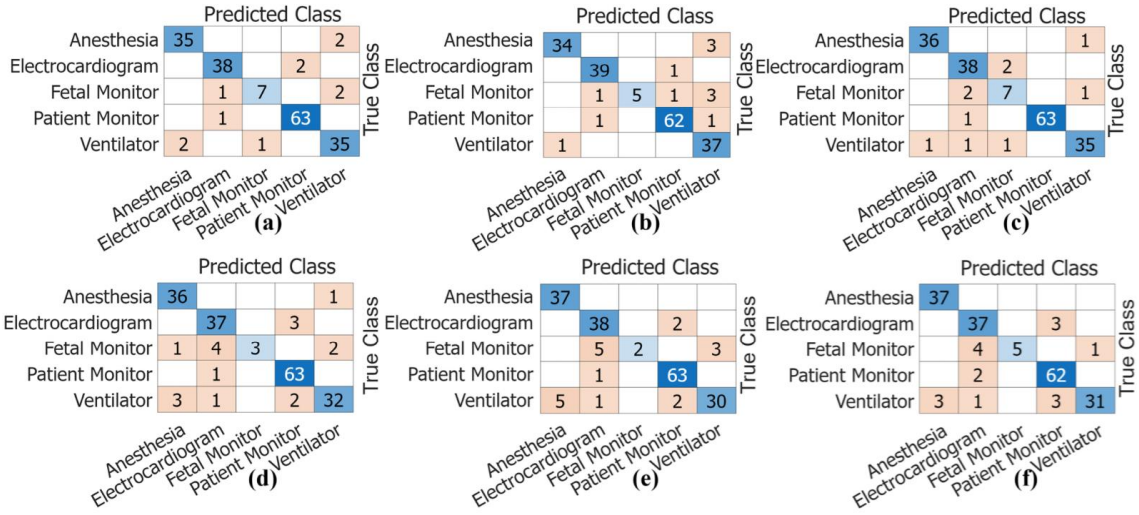
3.2.4.1. Destek Vektör Makineleri: Geleneksel makine öğrenimi algoritmalarından SVM; desen tanıma, görüntü analizi ve doğal dil işleme dâhil olmak üzere çeşitli alanlarda kullanılır. SVM, veri setinde bulunan örnekleri optimum olarak birbirinden ayıran hiper düzlemi elde ederek örneklerin sınıflarını belli eder. Hiper düzlem ile her sınıfa ait en yakın örnekler arasındaki mesafeye marj denir. Algoritma, bu marjı büyüterek hatayı en aza indirmeyi amaçlar.

3.2.4.2. K En Yakın Komşu Algoritması: Sınıflandırma ve regresyon görevleri için kullanılan popüler makine öğrenimi tekniklerinden biri de KNN algoritmasıdır. KNN, giriş veri noktası ile tüm eğitim örnekleri arasındaki mesafeyi Öklid mesafesi, Manhattan mesafesi vb. mesafe ölçüm metrikleriyle hesaplayarak mesafelerine göre giriş veri noktasına en yakın K komşuyu belirler. Sınıflandırma problemlerinde, algoritma K komşular arasında en yaygın sınıf etiketini giriş veri noktası etiketi olarak belirler. KNN'nin performansında K ve mesafe metriğinin seçimi etkilidir, bu sebeple optimum sonuçlar için parametre seçimi önemlidir.

4. BULGULAR

Bu tez çalışmasında, Medikal Cihaz 5 veri setinde bulunan tıbbi cihazlar yapay zekâ teknikleri kullanılarak sınıflandırılmıştır. Tez çalışmasının ilk aşamasında VGG16 ve ResNet-50'den çıkarılan öznitelikler SVM ve KNN ile sınıflandırılmıştır.

4.1. PERFORMANS DEĞERLENDİRMESİ



Şekil 4.1: Medikal Cihaz 5 veri seti karmaşıklık matrisleri **(a)** ve **(d)** VGG16 özniteliklerinin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması, **(b)** ve **(e)** ResNet-50 özniteliklerinin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması, **(c)** ve **(f)** VGG16 ve ResNet-50 özniteliklerinin birleştirilip Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması

Şekil 4.1'te, veri kümesinden ResNet-50 ve VGG16 modelleriyle ayrı ayrı çıkarılan özellikler ile bu özelliklerin birleştirilmesi sonucunda elde edilen özniteliklerin SVM ve KNN sınıflandırıcıları kullanılarak değerlendirilmesine ait karmaşıklık matrisi sonuçları sunulmuştur.

Tablo 4.1: VGG16 ve ResNet-50 modellerinden elde edilen özniteliklerin Destek Vektör Makinesi ile sınıflandırılmasına ilişkin sonuçlar

Model	Öznitelik Sayısı	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)	Doğruluk (%)
VGG16	1000	Anestezi	94,59	94,59	94,59	94,18
		EKG	95	95	95	
		Fetal Monitör	87,50	70	77,78	
		Hasta başı Monitör	96,62	98,44	97,67	
		Ventilatör	89,74	92,11	90,91	
RESNET50	1000	Anestezi	97,14	91,89	94,44	93,65
		EKG	95,12	97,50	96,30	
		Fetal Monitör	100	50	66,67	
		Hastabaşı Monitör	96,88	96,88	96,88	
		Ventilatör	84,09	97,37	90,24	
VGG16& RESNET50	2000	Anestezi	97,30	95	92,68	94,70
		EKG	90,48	100	98,82	
		Fetal Monitör	70	70	70	
		Hasta başı Monitör	100	98,44	99,21	
		Ventilatör	92,11	94,59	93,33	

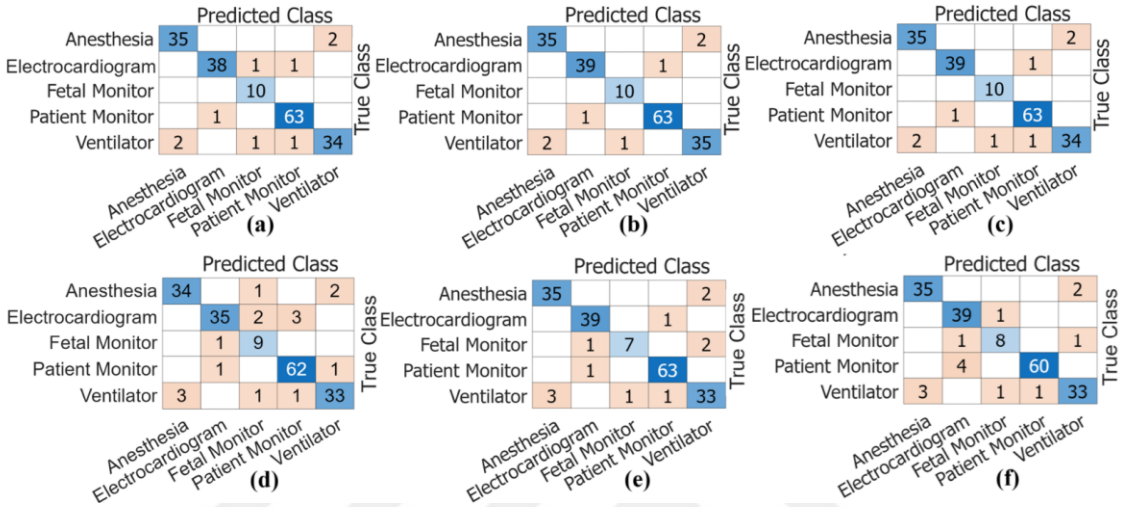
Tablo 4.2: VGG16 ve ResNet-50 modellerinden elde edilen özniteliklerin K En Yakın Komşu ile sınıflandırılmasına ilişkin sonuçlar

Model	Öznitelik Sayısı	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)	Doğruluk (%)
VGG16	1000	Anestezi	90	97,30	93,51	90,48
		EKG	86,05	92,50	89,16	
		Fetal Monitör	100	30	46,15	
		Hasta başı Monitör	92,65	98,44	95,45	
		Ventilatör	91,43	84,21	87,67	
RESNET50	1000	Anestezi	88,10	100	93,67	89,94
		EKG	84,44	95	89,41	
		Fetal Monitör	100	20	33	
		Hastabaşı Monitör	94,03	98,44	96,18	
		Ventilatör	90,91	78,95	84,51	
VGG16& RESNET-50	2000	Anestezi	92,50	100	96,10	91
		EKG	84,09	92,50	88,10	
		Fetal Monitör	100	50	66,7	
		Hastabaşı Monitör	91,18	96,68	93,94	
		Ventilatör	96,88	81,58	88,57	

Tablo 4.1 ve Tablo 4.2'de karmaşıklık matrisinde elde edilen verilere ait değerlendirme metrikleri sonuçları verilmiştir. Tablo 4.1 ve 4.2'deki sonuçlara bakıldığında, öznitelik birleştirmenin sınıflandırma başarısını önemli ölçüde artırdığı görülmektedir. Sınıflandırma algoritmalarının performansı incelendiğinde ise 2000 öznitelik için elde edilen genel doğruluk değeri SVM için %94,7 olarak elde edilmiştir.

KNN algoritması için ise bu sonuç %91'dir. Burada, SVM algoritmasının KNN'ye göre üstün bir performans sağladığı anlaşılmaktadır.

Tez çalışmanın bulgular kısmının ikinci adımda ise fMRMR algoritmasıyla seçilen 100, 200, 300 öznitelik için SVM ve KNN sınıflandırma sonuçları elde edilmiştir.



Şekil 4.2: Medikal Cihaz 5 veri seti birleştirilmiş özniteliklerin seçimi sonrası karmaşıklık matrisleri **(a)** ve **(d)** Seçilen 100 özniteliğin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması, **(b)** ve **(e)** Seçilen 200 özniteliğin Destek Vektör Makinesi ve K En Yakın Komşu ile sınıflandırılması, **(c)** ve **(f)** Seçilen 300 özniteliğin sınıflandırılması

Şekil 4.2'de fMRMR algoritması ile seçilen özniteliklerin sınıflandırma karmaşıklık matris sonuçları verilmiştir. Hata matrisleri dikkate alındığında seçilen 200 öznitelik için en yüksek doğruluk değeri elde edildiği görülmektedir. SVM sınıflandırıcı, seçilen 200 öznitelik için hata matrisinde sadece 7 hatalı tahmin yapımıştır. Tüm sınıflandırma matrisleri dikkate alındığında ise SVM sınıflandırıcısı, KNN sınıflandırıcısına göre daha başarılı sonuçlar elde etmiştir.

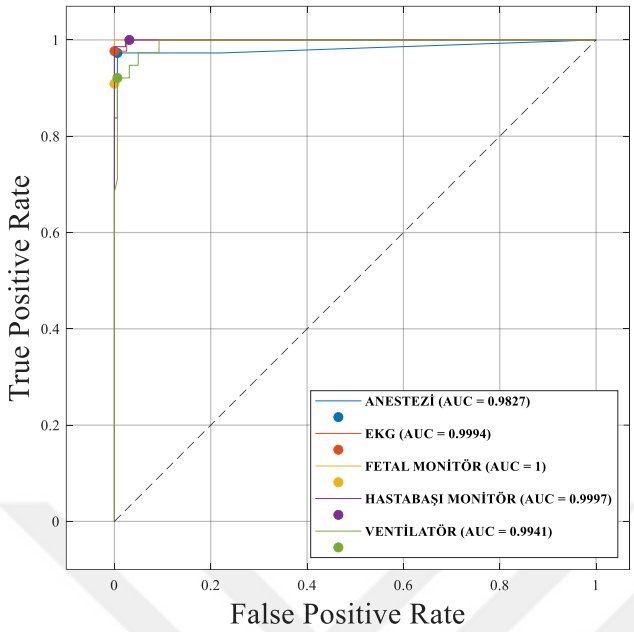
Tablo 4.3: Öznitelik seçimi sonrasında Destek Vektör Makinesi algoritması ile sınıflandırma sonuçları

Öznitelik Sayısı	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)	Doğruluk (%)
100	Anestezi	94,59	94,59	94,59	95,23
	EKG	97,44	95	96,20	
	Fetal Monitör	83,33	100	90,91	
	Hastabaşı Monitör	96,62	98,44	97,67	
	Ventilatör	94,44	89,47	91,89	
200	Anestezi	94,59	94,59	94,59	96,29
	EKG	97,50	97,50	97,50	
	Fetal Monitör	90,91	100	95,24	
	Hastabaşı Monitör	98,44	98,44	98,44	
	Ventilatör	94,59	92,11	93,33	
300	Anestezi	94,59	94,59	94,59	95,76
	EKG	97,50	97,50	97,50	
	Fetal Monitör	90,91	100	95,24	
	Hastabaşı Monitör	96,92	98,44	97,67	
	Ventilatör	94,44	89,47	91,89	

Tablo 4.4: Öznitelik seçimi sonrasında K En Yakın Komşu algoritması ile sınıflandırma sonuçları

Öznitelik Sayısı	Sınıflar	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)	Doğruluk (%)
100	Anestezi	91,89	91,89	91,89	91,53
	EKG	94,59	87,50	90,91	
	Fetal Monitör	69,23	90,00	78,26	
	Hastabaşı Monitör	93,94	96,88	95,38	
	Ventilatör	91,67	86,84	89,19	
200	Anestezi	92,11	94,59	93,33	93,65
	EKG	95,12	97,50	96,30	
	Fetal Monitör	87,50	70,00	70,00	
	Hastabaşı Monitör	96,92	98,44	98,44	
	Ventilatör	89,19	86,84	88,00	
300	Anestezi	92,11	94,59	93,33	92,59
	EKG	88,64	97,50	92,86	
	Fetal Monitör	80,00	80,00	80,00	
	Hastabaşı Monitör	98,36	93,75	96,00	
	Ventilatör	91,67	86,84	89,19	

Tablo 4.3 ve Tablo 4.4'te karmaşıklık matrislerinin değerlendirme metrikleriyle elde edilen sonuçlar sunulmuştur. Tablo 4.3'te yer alan sonuçlara göre, SVM algoritması ile yapılan sınıflandırmada en yüksek doğruluk değeri %96,29 ile 200 öznitelik seçimi sonucunda elde edilmiştir. Benzer şekilde, KNN algoritmasında da 200 öznitelikle %93,65 oranında genel doğruluk sağlanarak en iyi performans yakalanmıştır.



Şekil 4.3: Medikal Cihaz 5 veri setinde, 200 öznitelik kullanılarak elde edilen sınıflandırma sonuçlarına ilişkin Alıcı İşletim Karakteristiği eğrisi

Şekil 4.3'te, sınıflandırma modelinin her bir sınıf için ürettiği Receiver Operating Characteristic (ROC) eğrileri sunulmuştur. ROC eğrisi, yanlış pozitif oran ile doğru pozitif oran arasındaki ilişkiyi grafiksel olarak gösterir. Modelin sınıflandırma başarısını değerlendirmek amacıyla kullanılan bu eğriler, aynı zamanda her sınıf için elde edilen Area Under Curve (AUC) değerlerini de içermektedir. Elde edilen AUC değerleri fetal monitör sınıfı için 1,0000; hasta başı monitör sınıfı için 0,9997; EKG sınıfı için 0,9994; ventilatör sınıfı için 0,9941; anestezi sınıfı için ise 0,9827'dir.

Modelin sınıfı doğru şekilde ayırt etme performansı AUC değeri 1'e yaklaştıkça artar. ROC grafiğinde, modelin tüm sınıflarda oldukça yüksek bir ayırt edicilik performansı sergilediği görülmektedir. Modelin tüm sınıflar için AUC > 0,98 başarımı göstermesi, genel olarak yüksek doğruluk ve düşük hata oranlarıyla çalıştığını ve sınıflar arasında tutarlı bir ayrım gücü sunduğunu ortaya koymaktadır.

5. TARTIŞMA

Tıbbi cihazlar sağlık hizmetlerinin sağlanmasında sağlık profesyonellerinin en önemli ekipmanlarındandır. Sağlık hizmetlerinin sağlanmasında hizmetin aksamadan ve gerektiğinde hemen sağlanması hasta sağlığı açısından hayati önem taşımaktadır. Tıbbi cihazların gerektiğinde hazır olmaları ise ancak doğru bir envanter yönetimi ile sürekli hale getirilebilir. Tıbbi cihaz envanter doğruluğunun optimize edilmesinde manuel yöntemler yerine yapay zekâ destekli algoritmaların kullanılması, sürecin hızlandırılması ve doğruluğun artırılması için bir gerekliliktir. Bu tez çalışması kapsamında Medikal Cihaz 5 veri seti kullanılmıştır. Medikal Cihaz 5 veri seti kullanılarak beş farklı cihaz türüne ait görüntülerin sınıflandırılması ve bu modelin envanter yönetim sistemlerine entegrasyonu hedeflenmiştir. Böylece, farklı deneyim düzeylerine sahip envanter çalışanlarının binlerce cihaz türünü daha doğru ve hızlı şekilde tanımlayabilmesi amaçlanmaktadır. Bu bölümde, yapay zekâ algoritmalarının medikal cihazların sağlık hizmetlerinde daha etkin kullanımına yönelik literatürde yapılan çalışmalar özetlenmiştir.

Wu ve ark. (63), COVID-19 pandemisi bağlamında medikal ve hemşirelik personelinin güvenliğini sağlamak amacıyla, tıbbi kişisel koruyucu ekipmanların doğru ve gerçek zamanlı tespiti için geliştirilmiş bir model olan ME-YOLO'yu önermiştir. Çalışma, omurga ağının özellik çıkarma yeteneğini artırmak için C3 modülüyle entegre edilmiştir. Özellik Birleşim Modülü ve semantik bilgileri korumak amacıyla Yukarı Örnekleme Geliştirme Modülü geliştirilmiştir. Ayrıca, daha yüksek konumlama doğruluğu elde etmek amacıyla, sınır kutusu regresyon kaybı olarak Kesişim üzerinde Birleşim temelli bir kayıp fonksiyonu kullanılmıştır. Yapılan deneysel analizlerde ME-YOLO modeli, %97,2 oranında ortalama doğruluk ve saniyede 53 kare işlem kapasitesiyle yüksek doğruluk ve hız dengesini başarıyla sağlamıştır. Böylece gerçek zamanlı nesne tespiti gereksinimlerini karşılamıştır.

Moktar ve ark. (64), Internet of Things (IoT) ve YOLO modellerinin entegrasyonu ile medikal atıkların otomatik sınıflandırılması ve ayrıştırılması amacıyla geliştirdikleri sistemde, YOLO v5'ten YOLO v9'a kadar farklı modelleri eğitip karşılaştırmıştır. YOLO v8'in %98 ortalama doğruluk, %95,8 hassasiyet ve %96,3 duyarlılık değerleriyle en iyi performansı gösterdiğini raporlamıştır. Geliştirilen prototip; maske, eldiven, şırınga ve kesici atık gibi medikal atıkları yüksek doğrulukla tespit ve sınıflandırabilmekte olup

sürdürülebilir sağlık hedefleri doğrultusunda gerçek dünya uygulamalarına uygun, etkili bir çözüm sunmaktadır.

Ceross ve Bergmann (65), medikal cihazların risk bazlı sınıflandırılması süreçlerini kolaylaştırmak amacıyla, Avustralya'nın Therapeutic Goods Authority tarafından sunulan çevrimiçi dijital sınıflandırma aracını değerlendirmiştir. Çalışmanın ilk bölümünde, yasal düzenlemelerin okunabilirliği Flesch okuma kolaylığı skoru ile karşılaştırılmış ve çevrimiçi aracın mevzuata göre daha anlaşılır olduğu bulunmuştur. İkinci bölümde ise cihazların amaçlarına göre sınıflandırılması için geliştirilen makine öğrenmesi tabanlı kavramsal model %82 ağırlıklı doğruluk elde etmiş, bu da veri odaklı yaklaşımların düzenleyici kurumlar tarafından benimsenmesinin etkinliği artırabileceğini göstermiştir.

Kumar ve ark. (66), IoT destekli sağlık cihazlarının sınıflandırılmasında makine öğrenmesi ve derin öğrenme yöntemlerini incelemişlerdir. Çalışmada, IoT'nin kişiselleştirilmiş sağlık sistemlerine geçişteki rolü, avantajları ve karşılaşılan zorluklar detaylı şekilde ele alınmıştır. Araştırma, farklı makine öğrenmesi ve derin öğrenme algoritmalarının IoT tabanlı sağlık uygulamalarında başarıyla kullanıldığını, böylece sağlık profesyonelleri ile hastalar arasında etkileşimin güçlendiğini ve kritik medikal durumların daha etkili teşhis edildiğini ortaya koymuştur.

Kovačević ve ark. (67), medikal cihaz yönetiminde makine öğrenmesi tekniklerinin uygulanmasını inceleyerek yenidoğan kuvözlerinin performansını değerlendirmiştir. 2015-2017 yılları arasında toplanan 140 örnek üzerinden geliştirilen uzman sistemde Naive Bayes, Karar Ağacı, Random Forest, KNN ve SVM algoritmaları test edilmiştir. En yüksek doğruluk oranı %98,5 ile Karar Ağacı algoritmasında elde edilmiş olup sonuçlar makine öğrenmesi uygulamalarının hasta güvenliği ve tedavi kalitesinin artırılmasının yanı sıra maliyet optimizasyonu ve kaynak yönetimi açısından sağlık kurumlarına önemli faydalar sağlayabileceğini göstermektedir.

Rowan ve ark. (68), yeniden kullanılabilir medikal cihazların temizliği, dezenfeksiyonu ve sterilizasyonu için 1957'de önerilen Spaulding sınıflandırma sistemini modern perspektiften incelemişlerdir. Yapılan kapsamlı literatür taraması sonucu, sistemin kolay uygulanabilirliği ve kullanıcılar tarafından anlaşılabilirliği nedeniyle hâlen yaygın olarak kullanıldığı ancak yeni patojenlerin ortaya çıkışı, mikroorganizmaların dezenfektanlara karşı artan direnç mekanizmaları ve medikal cihazların giderek

karmaşıklaşan tasarımları nedeniyle güncellenmesi gerektiği vurgulanmıştır. Özellikle duodenoskop gibi yüksek riskli esnek endoskopların sınıflandırmasının yarı kritikten kritik düzeye yükseltilmesi ve düşük ısı sterilizasyon yöntemlerinin benimsenmesi önerilmektedir. Ayrıca yapay zekâ ve makine öğrenmesi destekli gerçek zamanlı izleme sistemlerinin, cihaz işleme süreçlerinin tüm aşamalarında etkin temizlik ve sterilizasyonun sağlanması için gerekliliği üzerinde durulmaktadır. Çalışma, medikal cihaz sektöründe sürdürülebilirlik için akademi, sanayi, sağlık, düzenleyiciler ve toplumun birlikte hareket ettiği yeni yaklaşımlar önermektedir.

Spahić ve ark. (69), gerçek zamanlı ölçülen verilere dayalı yenidoğan kuvözlerinin performansını tahmin etmek için YSA ve bulanık mantık tabanlı bir uzman sistem geliştirmiştir. Girdi parametreleri olarak sıcaklık hatası, önleyici bakım aralıkları, ek parça sayısı ve kullanım katsayısı kullanılmıştır. 12 gizli katman nöronlu geri beslemeli YSA, Bayesyen düzenleme algoritması ile kuvöz performansını tahmin etmede en iyi sonuçları vermiştir. Mamdani çıkarım mantığına dayalı bulanık mantık ise YSA'nın genişletilmesi olarak uygulanmıştır. Geliştirilen sistem, medikal cihaz yönetim stratejilerinin geliştirilmesi ve hasta güvenliğinin artırılması için önemli bir adım olarak değerlendirilmektedir.

Zhou ve ark. (70), medikal atıkların tanımlanması ve sınıflandırılması için derin öğrenme tabanlı bir yöntem önermiştir. ResNeXt mimarisini temel alan model, transfer öğrenme teknikleriyle desteklenmiş ve 3480 görüntü üzerinde gerçekleştirdiği deneylerde %97,2 doğruluk ve ortalama F1-skoruna ulaşmıştır. Çalışma, çevresel koruma bağlamında acil çözüm gerektiren medikal atık sınıflandırma sorununa yönelik otomatik, yüksek doğruluklu bir yapay zekâ çözümü sunmakta olup bu teknolojinin Çin genelinde yaygın kullanım potansiyeline sahip olduğunu vurgulamaktadır.

Moktar ve ark. (71), tıbbi atıkların sınıflandırılması ve yönetiminde modern yapay zekâ yöntemlerini değerlendirmiştir. Çalışmada ESA, ResNet50, YOLO v3 ve YOLO v4 modelleri karşılaştırılmış olup YOLO v4 %89,21 ortalama hassasiyet değeri ile en yüksek başarıyı göstermiştir. Model; maske, eldiven ve şırınga gibi tıbbi atıkları başarılı şekilde tespit etmiş ve nesne algılama performansı açısından üstünlük sağlamıştır. Araştırma, tıbbi atık tespiti ve sınıflandırmasının geliştirilmesi için ek performans iyileştirmelerinin gerektiğini vurgulamaktadır.

Ahmed ve Shanto (72), COVID-19 sonrası medikal atık yönetiminde cerrahi atıkların tespiti için YOLO tabanlı derin öğrenme algoritmalarının performans analizini gerçekleştirmiştir. MSG veri seti kullanılarak YOLOv5, YOLOv7 ve YOLOv8 mimarilerinin karşılaştırıldığı çalışmada, YOLOv8-m modeli %82,4 ortalama hassasiyet değeri ile en yüksek başarıyı elde etmiştir. Araştırma, cerrahi maske ve eldiven gibi enfeksiyon riski taşıyan atıkların otomatik sınıflandırılması yoluyla, enfeksiyon risklerinin azaltılması ve atık yönetim süreçlerinin iyileştirilmesi için bu modellerin kullanılabileceğini ortaya koymaktadır.

Hidayat ve ark. (73), hastane ortamlarında kısmen gizlenmiş medikal ekipmanların tespiti için gelişmiş bir nesne algılama modeli olan YOLOv8'in uygulanmasını incelemiştir. Çalışmada, %30-50 arası görünürlük engelleri altında farklı medikal cihaz kategorileri değerlendirilmiş ve YOLOv8 modeli, engellenmeyen durumlarda %93,8 F1 skoru ve doğruluk, kısmi gizlenme koşullarında ise sırasıyla 0,889 ve %86,7 performans değerleri elde etmiştir. Model, görünürlük azaldıkça güven skoru değerlerinde sistematik bir düşüş göstermesine rağmen, kısmi örtülme durumlarında bile etkili tespit yapabilmekte ve belirsizlik ölçümü sağlamaktadır. Bulgular, otomatik medikal ekipman tespiti alanında önemli bir ilerleme sunmakla birlikte, farklı klinik ortamlar için daha kapsamlı doğrulamalara ihtiyaç duyulduğunu ortaya koymaktadır.

Pan ve ark. (74), laparoskopik cerrahi videolarında cerrahi aletlerin doğru tespiti ve analizine yönelik uçtan uca bir algoritma olan DBH-YOLO'yu önermiştir. Çalışmada hem konumlandırma hem sınıflandırma doğruluğunu artırmak amacıyla Çift Dallanmış Baş (Dual-Branched Head) ve Genel Kesişim Üzerinden Birliktelik Kaybı (Overall Intersection over Union Loss) teknikleri geliştirilmiştir. Yeni oluşturulan LGIL veri seti ile birlikte veri setlerinde yapılan testlerde model sırasıyla %96,8; %95,6 ve %98,4 ortalama doğruluk değerleri elde ederek klasik yöntemlere göre üstün performans göstermiştir. DBH-YOLO, benzer cerrahi alet sınıflarını ayırt etmede ve yanlış pozitif ile eksik tespit oranlarını azaltmada etkili olup iyi bir genelleme yeteneğine sahiptir.

Yapılan literatür incelemeleri, medikal cihazlarla ilgili birçok çalışmanın mevcut olduğunu ortaya koymaktadır. Mevcut literatürün ağırlıklı olarak tıbbi cihaz ekipmanları ve nesne tanıma alanlarına yoğunlaştığı görülmektedir. Önerilen tez kapsamında geliştirilen yöntem ve elde edilen bulgular, tıbbi cihazların sınıflandırılması alanında literatüre özgün bir katkı sunmuştur.

Medikal Cihaz 5 veri seti cihaz sınıflarındaki görüntü sayıları dikkate alındığında sınıflar arasındaki dağılım dengesiz olarak kabul edilmektedir. Veri setindeki sınıfların örnek sayılarının dengesiz olduğu modellerde, çok sayıda örneği olan sınıflar algoritmanın ağırlıklarını belirlemede etkili olmaktadırlar. Bu durum örnek sayısı fazla olan sınıflar için aşırı uydurma ile sonuçlanabilmektedir. Dengesiz veri setlerinde olası sorunların üstesinden gelmek için birçok çalışmada görüntü artırma yöntemleri, sentetik veri oluşturma teknikleri, maliyete duyarlı öğrenme yöntemleri gibi teknikler kullanılmıştır. Bu tez çalışmasında ise görüntü artırma teknikleri kullanılarak eğitim veri setindeki görüntü sayısı en yüksek sınıf sayısı ile eşitlenmiştir. Literatürde görüntü artırma teknikleri kullanılarak yapılan yapay zekâ çalışmaları oldukça fazladır ve bazıları sonraki paragraflarda verilmiştir.

Ding ve ark. (75), medikal görüntü sınıflandırmada veri dengesizliği sorununa yönelik olarak Generative Adversarial Network (GAN) tabanlı bir veri artırma yöntemi geliştirmiştir. Çalışmada, seyrek örneklerin daha iyi öğrenilmesi hedeflenmiş ve One-Class SVM filtresiyle yüksek kaliteli sentetik örnekler elde edilmiştir. Dört farklı medikal veri setinde yapılan deneylerde, önerilen yaklaşımın örnek çeşitliliğini artırarak sınıflandırma doğruluğunu yaklaşık %3 oranında iyileştirdiği gösterilmiştir.

Beddiar ve ark. (76), COVID-19'un tıbbi görüntülerden tespitinde veri eksikliğini gidermek amacıyla derin öğrenme tabanlı yenilikçi bir veri artırma yöntemi geliştirmiştir. Çalışmada, orijinal görüntülerdeki gürültü/sinyal oranını koruyacak şekilde, DnCNN tabanlı denoising ve Gaussian gürültü ekleme adımlarından oluşan karmaşık bir artırma süreci uygulanmıştır. Elde edilen artırılmış veri setleri Zamansal ESA ile COVID-19 ve non-COVID-19 sınıflarına ayrılmış; üç farklı Covid-19 görüntü veri setinde yapılan deneylerde yöntemin, mevcut çalışmalarla karşılaştırıldığında yüksek doğruluk ve sağlamlık sağladığı rapor edilmiştir.

Zhang ve ark. (77), küçük ölçekli ve dengesiz tıbbi görüntü veri kümelerinde derin sinir ağlarının eğitim zorluklarını aşmak amacıyla, GAN tabanlı sentetik veri artırma yöntemi geliştirmiştir. Önerilen yöntem sayesinde, duyarlılık %84,2'ye ve özgüllük %92,1'e yükselerek klasik veri artırma tekniklerine kıyasla sınıflandırma performansında kayda değer iyileşmeler sağlanmıştır.

Mikołajczyk (78), derin öğrenme tabanlı görüntü sınıflandırma problemlerinde veri yetersizliği ve dengesiz sınıf dağılımı sorunlarını gidermek amacıyla, klasik

dönüşümlerden (döndürme, kırpma, yakınlaştırma) stil transferi ve üretici adversarial ağlara kadar çeşitli veri artırma yöntemlerini karşılaştırmış ve analiz etmiştir. Çalışmada önerilen stil transferine dayalı veri artırma yöntemi, tıbbi görüntüleme örneklerinde (cilt melanom tanısı, histopatolojik görüntüler) kullanılarak sınıflandırma performansını iyileştirmede başarılı sonuçlar vermiştir.

Abdollahi ve ark. (79), sınırlı etiketli veri setlerine dayalı derin öğrenme modellerinin daha genelleştirilebilir ve doğru olmasını sağlamak için veri artırma tekniklerinin önemini vurgulamıştır. Özellikle tıbbi görüntü analizinde, etiketli veriye erişimin kısıtlı olması nedeniyle, uygun veri artırma yöntemlerinin seçimi kritik hale gelmektedir. Bu çalışmada, yaygın kullanılan görüntü artırma teknikleri ve özellikleri incelenmiş; ayrıca, tıbbi görüntü analizine özgü uygulamalarda faydalı olan yöntemler değerlendirilmiştir. Amaç, anotasyon eksikliği veya sınırlı veri bulunan tıbbi görüntü analiz uygulamalarında derin öğrenme modellerinin eğitimi için rehberlik sağlamaktır.

Liu ve ark. (80), derin öğrenme tabanlı tıbbi görüntü sınıflandırmalarında çeşitli veri artırma yöntemlerinin model açıklanabilirliğine etkisini incelemiş; göğüs röntgeni veri setlerinde DenseNet121 modeliyle yapılan deneylerde, Yerel Yorumlanabilir Modelden Bağımsız Açıklamalar ve SHapley Eklemeli Açıklamaları yöntemleri kullanılarak açıklanabilirliğin doğruluk ve tutarlılık açısından değerlendirildiğini belirtmişlerdir. Çalışmada TrivialAugment yönteminin genel olarak en yüksek tamlık ve tutarlılık sağladığı, Yerel Yorumlanabilir Modelden Bağımsız Açıklamalar yönteminin SHapley Eklemeli Açıklamalarına göre daha iyi tutarlılık performansı gösterdiği rapor edilmiştir.

Chen ve Cao (81), tıbbi alanda veri yetersizliğini aşmak amacıyla GAN yöntemini kullanarak mevcut verilerden gerçekçi yeni örnekler üreten ve ardından ESA ile şüpheli lezyonları sınıflandıran derin öğrenme tabanlı model önermişlerdir. Diyabetik retinopati teşhisinde uygulanan yöntem, geleneksel derin öğrenme yaklaşımlarına kıyasla daha üstün sınıflandırma performansı sergilemiştir.

Rais ve ark. (82), tıbbi görüntü sınıflandırmasında veri artırma yöntemlerinin etkisini karşılaştırmışlardır. Çalışmada, geleneksel geometrik ve fotometrik dönüşümlerin yanı sıra derin öğrenmeye dayalı yaklaşımlar, özellikle DCGAN ve AttnGAN gibi jeneratif modeller kullanılmıştır. BraTS20 beyin tümörü segmentasyon

veri setinde uygulanan bu yöntemler, ESA sınıflandırma doğruluğunu önemli ölçüde artırmış ve özellikle DCGAN ile AttnGAN, yüksek doğruluk ve gerçekçi görüntü üretimi sağlamıştır.

Qi ve ark. (83), sınırlı sayıda anotasyona sahip tıbbi görüntüler için yarı denetimli dikkatli GAN tabanlı veri artırma yöntemi olan SAG-GAN'i geliştirmiştir. Model, tümör ve normal görüntüleri iki farklı alan olarak ele alarak, normal görüntülerden tümörlü, tümörlü görüntülerden ise normal yapay görüntüler üretmektedir. Elde edilen sentetik veriler, ResNet18 tabanlı sınıflandırma modellerinin performansını artırmış; klasik veri artırma yöntemlerine kıyasla doğruluk ve AUC değerlerinde anlamlı iyileşmeler sağlamıştır. Çalışma, özellikle tümör Manyetik Rezonans Görüntüleme (MRI) üzerinde sınırlı veri koşullarında etkili sonuçlar vermiştir ve yöntemin diğer tıbbi görüntü alanlarında da uygulanabilirliği vurgulanmıştır.

Huang ve ark. (84), tıbbi görüntü sınıflandırmasında veri eksikliğini gidermek için yapısal benzerlik kaybı kullanan, geliştirilmiş bir Progressive Growing GAN modelini önermiştir. Bu model, 256x256 çözünürlükte daha gerçekçi ve çeşitli tümör MR görüntüleri üreterek klasik GAN'ların bulanıklık ve mod çökmesi sorunlarını azaltmıştır. Sentetik veriler, geleneksel yöntemlere göre daha iyi sonuçlar vermiştir. Bu çalışma, veri çeşitliliğini artırmanın tıbbi görüntü sınıflandırma performansı üzerinde olumlu bir etki yarattığını ortaya koymaktadır.

Llambias ve ark. (85), tıbbi görüntülemede donanım ve protokol farklılıklarından kaynaklanan veri heterojenliğinin üstesinden gelmek için, beyin MR görüntü segmentasyonunda MRI'ye özgü artırma tekniklerini kullanan denetimsiz alan uyarlama yöntemi geliştirmiştir. Önerilen yöntem, çeşitli veri setleri ve görevlerde yapılan kapsamlı deneylerde yüksek doğruluk ve güçlü genellenebilirlik göstererek çoğu durumda güncel yöntemlerin performansını aşmıştır. Bu çalışma, tıbbi görüntü analizinde alan farklılıklarının etkisini azaltmada etkili bir çözüm sunmaktadır.

Safdar ve ark. (86), beyin tümörü MRI verisinde veri artırma tekniklerini karşılaştırmıştır. Düşük dereceli glioma hastalarına ait 1961 adet görüntüde, YOLOv3 modeli orijinal ve artırılmış veri setleriyle ayrı ayrı eğitilmiştir. Deney sonuçları, 90° ve 180° dönüş yöntemlerinin tıbbi görüntü verisi artırmada en etkili teknikler olduğunu

göstermiştir. Bu çalışma, özellikle düşük hacimli tıbbi görüntü verilerinde dönüş bazlı veri arttırma yöntemlerinin faydalı olduğunu ortaya koymaktadır.

Liu ve ark. (87), tıbbi görüntü segmentasyonunda yerel görüntü deformasyonu esaslı yeni bir veri artırma yöntemi olan stokastik evrim yöntemini önermiştir. Bu yöntem, hastalıklı dokunun bozulma ve iyileşme süreçlerini simüle ederek doğal görünümlü örnekler üretmektedir. Meme kitleleri, prostat, beyin tümörleri ve akciğer nodüllerinde yapılan segmentasyon deneylerinde, Stokastik evrim yöntemi özellikle Dice Benzerlik Katsayısı ve duyarlılık metriklerinde belirgin iyileşmeler sağlamıştır. Dice Benzerlik Katsayıları sırasıyla %5,2; %2,8; %1,0 ve %3,2 artarken duyarlılık değerleri %6,9; %4,3; %1,2 ve %4,5 oranlarında yükselmiştir. Bu çalışma, farklı görüntü veri setleri ve modalitelerde sağlamlık göstererek tıbbi görüntü segmentasyonunda veri artırma için etkili bir yaklaşım sunmaktadır.

He ve Chu (88), derin öğrenmeye dayalı 3D tıbbi görüntü sınıflandırmasında veri artırma ve sinir ağı mimarisi tasarımını eş zamanlı optimize eden MedPipe yöntemini geliştirmiştir. Geleneksel otomatik veri artırma ve mimari arama tekniklerinin birbirinden bağımsız çalışmasının performans sınırlamalarını ele alan çalışma, veri artırma ve mimariyi tek bir ağ içinde bütünleştirerek ortak optimizasyon sağlamıştır. Dokuz farklı tıbbi veri seti üzerinde yapılan deneylerde MedPipe yöntemi, veri artırma ve mimari aramanın birlikte yürütülmesinin performansı anlamlı şekilde artırdığını göstermiştir. Bu yaklaşım, tıbbi görüntü analizinde özelleştirilmiş veri artırma stratejileri ile uyumlu sinir mimarilerinin önemini vurgulamaktadır.

Mikołajczyk ve Grochowski (89), derin öğrenmede sıkça karşılaşılan veri eksikliği ve sınıf dengesizliği sorunlarına çözüm olarak veri artırma yöntemlerini karşılaştırmış ve analiz etmiştir. Çalışmada, klasik görüntü dönüşümleri ile stil transferi ve GAN tabanlı yöntemler gibi çeşitli teknikler incelenmiştir. Ayrıca, temel görüntü içeriği ile farklı bir stil görünümünü birleştiren stil transferi tabanlı özgün bir veri artırma yöntemi geliştirilmiştir. Bu yöntem, deri melanomu tanısı, histopatolojik görüntüler ve meme MR incelemeleri gibi üç tıbbi uygulama üzerinde doğrulanarak, sınırlı veri setlerinde ön eğitim için etkili olduğu gösterilmiştir. Çalışmada, tıbbi görüntü sınıflandırmasında veri artırmanın avantajları ve sınırlılıkları detaylı biçimde tartışılmıştır.

Zhao ve ark. (90), tıbbi görüntü segmentasyonu alanında, ESA temelli yöntemlerin yüksek doğruluk sağladığını ancak büyük etiketli veri setlerine ihtiyaç duyduğunu belirtmiştir. Etiketleme işleminin uzmanlık ve zaman gerektirmesi nedeniyle, geleneksel veri artırma yöntemlerinin karmaşık varyasyonları yakalamakta yetersiz kaldığı vurgulanmıştır. Bu çalışmada, yalnızca tek bir etiketli MRI beyin taraması kullanılarak yarı denetimli bir yaklaşımla otomatik veri artırma yöntemi geliştirilmiştir. Model, uzaysal deformasyon ve yoğunluk değişikliklerini içeren dönüşümleri öğrenerek etiketli örnekleri sentezler. Önerilen yöntem, özellikle tek örnekli tıbbi görüntü segmentasyonu görevlerinde mevcut yöntemlere kıyasla anlamlı performans artışı sağlamaktadır.

Veri setini eğitmek için, benzer çalışmalarda yüksek başarı sağlayan VGG16 ve ResNet50 modelleri tercih edilmiştir. VGG16 ve ResNet-50 mimari olarak farklılıklar içermektedirler. Mimarilerin farklılığından kaynaklı olarak elde edilen özniteliklerin birleştirilmesiyle farklı öznitelikler elde edilmiştir. Böylece, birleştirme tekniğiyle SVM ve KNN sınıflandırma sonuçlarının VGG16 ve ResNet-50'den daha yüksek olduğu bulgular bölümünde belirtilmiştir. Derin öğrenme modellerinden elde edilen özniteliklerin birleştirilmesiyle daha ayırt edici özellik alt kümesi elde edilmiştir. Literatür incelendiğinde benzer çalışmalarla karşılaşılmıştır.

Taşci (91), COVID-19'un X-ray görüntülerinden otomatik teşhisi için derin öğrenme ve özellik seçme yöntemlerini bir araya getirerek bir yaklaşım sunmuştur. Çalışmada dokuz farklı derin öğrenme modeli ve mRMR gibi özellik seçme teknikleri kullanılmış, en yüksek doğruluk %98,21 ile ResNet50 ve AlexNet tabanlı Kubik SVM modelinde elde edilmiştir. Bu sonuçlar, derin öğrenme tabanlı sistemlerin COVID-19 teşhisinde yüksek potansiyele sahip olduğunu göstermektedir.

Özyurt (92), uzaktan algılama görüntü tanıma görevlerinde AlexNet, VGG16, VGG19, GoogleNet, ResNet ve SqueezeNet gibi önceden eğitilmiş derin ağlardan elde edilen özellikleri kullanarak hızlı ve doğru sınıflama sağlayan yeni bir yaklaşım önermiştir. Relief algoritmasıyla seçilen derin özelliklerin SVM sınıflayıcıya verilmesiyle, %99,29'a varan yüksek doğruluk oranları elde edilmiştir. Yöntemin veri eksikliği ve aşırı öğrenme problemlerine karşı etkili olduğu gösterilmiştir.

Nijaguna ve ark. (93), tıbbi teşhis uygulamalarında dengesiz veri dağılımı ve aşırı öğrenme sorunlarına çözüm olarak Quantum Fruit Fly algoritmasıyla desteklenen

ResNet50 ve VGG16 tabanlı yenilikçi bir yöntem geliştirmiştir. Çalışmada, Min-Max normalizasyonuyla iyileştirilen görüntülerden derin özellikler çıkarılmıştır. Archimedes spiral arama stratejisiyle Quantum Fruit algoritması ile en ayırt edici özellikler seçilerek SVM sınıflayıcıya aktarılmıştır. Yöntem, %99,26 duyarlılık ve %99,04 doğruluk gibi üstün performans sonuçlarıyla mevcut yöntemlere kıyasla önemli iyileştirmeler sağlamıştır.

Velpula ve ark. (94), beyin tümörü teşhisinde invaziv ve zaman alıcı biyopsi temelli yöntemlerin sınırlamalarını aşmak amacıyla, MRI görüntülerinden tam otomatik sınıflama için derin öğrenme ve makine öğrenmesi tekniklerini entegre eden bir model geliştirmiştir. Çalışmada, VGG tabanlı mimarilerden elde edilen doku özellikleri, SVM, KNN ve AdaBoost gibi çeşitli sınıflayıcılara aktarılmış ve GridSearchCV ile hiperparametre optimizasyonu yapılmıştır. VGG16 ve VGG19 tabanlı sistemlerde sırasıyla %96,30 ve %94,02 doğruluk elde edilerek yöntemin erken teşhis ve tanısal doğruluk açısından güçlü katkılar sunduğu gösterilmiştir.

Kharthik ve ark. (95), kritik altyapıların etkin yönetimi için yüzey çatlaklarının otomatik tespiti amacıyla transfer öğrenmeli DCNN tabanlı bir yaklaşım geliştirmiştir. SVM entegrasyonu ile performansını karşılaştırmalı olarak incelemiştir. Çalışmada SDNET, CCIC ve BSD veri kümelerinde 12 farklı transfer öğrenmeli DCNN modeli değerlendirilmiş; ResNet101, SDNET üzerinde %53,40; EfficientNetB0, BSD üzerinde %98,8 ve ResNet50, CCIC üzerinde %99,8 doğruluk sağlamıştır. Ayrıca, görüntü iyileştirme teknikleri ve derin özelliklerin SVM ile birleşimi, tüm veri kümelerinde doğruluk, hassasiyet, duyarlılık ve F1 skorlarında anlamlı artış göstermiş; yöntemin çatlak tespitinde etkinliğini ortaya koymuştur.

Yaman ve ark. (96), beyin hastalıklarının MR görüntülerinden otomatik teşhisi için AlexNet ve GoogleNet tabanlı derin özelliklerle desteklenen, çift yinelemeli Relief algoritmasını içeren bir yöntem geliştirmiştir. Bu algoritma ile seçilen 688 özellik SVM sınıflayıcıda kullanılarak %98,87 (10 katlı çapraz doğrulama) ve %95,96 (kamu MRI veri kümesi) doğruluk elde edilmiş, yöntemin erken ve doğru teşhis için güçlü bir potansiyele sahip olduğu gösterilmiştir.

Danaci ve ark. (97), pes planus hastalığının X-ray görüntülerinden teşhisi için; Relief-F, Lasso ve RFE tabanlı özellik seçimiyle desteklenen; KNN, SVM, XGBoost ve CatBoost algoritmalarını içeren; yapay zekâ temelli bir yöntem geliştirmiştir. Relief ile

seçilen 300 özellik kullanılarak XGBoost algoritması %97 doğruluk elde etmiş ve yöntem, literatürdeki sınırlı çalışmalara kıyasla yüksek başarı oranıyla erken teşhis süreçlerini optimize etme potansiyeli göstermiştir.

Attallah ve Samir (98), COVID-19'un hızlı ve doğru teşhisi için çoklu açılardan elde edilen bilgisayarlı tomografi dilimlerini kullanan CoviWavNet adlı, dalgacık tabanlı bir derin öğrenme yöntemi geliştirmiştir. Çalışmada, çok seviyeli ayrık dalgacık dönüşümü ile elde edilen spektral-zamansal bilgiler ve orijinal bilgisayarlı tomografi görüntülerinden çıkarılan derin uzamsal özellikler birleştirilmiş, ardından seçilen özellikler SVM sınıflayıcılarda kullanılmıştır. OMNIAHCOV ve SARS-COV-2-CT-Scan veri kümelerinde sırasıyla %99,33 ve %99,7 doğruluk elde edilerek yöntemin COVID-19 teşhisinde yüksek başarım ve klinik fayda sağladığı gösterilmiştir.

Malik ve ark. (99), MURA veri setinden alınan 16.984 dirsek röntgeni üzerinde yapılan çalışmada, derin öğrenme ve el yapımı özelliklerin füzyonunu ve balina optimizasyon algoritması ile özellik seçimini içeren bir yöntem önermiştir. Darknet-53 ve Xception modelleriyle derin özellikler, Yönlendirilmiş Gradyanların Histogramı ve Yerel İkili Desenler ile el yapımı özellikler çıkarılmıştır. Temel Bileşen Analizi ile en bilgilendirici özellikler seçilmiştir. SVM, KNN ve geniş YSA sınıflayıcıları ile yapılan sınıflandırmada %97,1 doğruluk ve %94,3 kappa skoru elde edilmiştir. Önerilen yöntem, literatürdeki güncel yaklaşımlara kıyasla üstün performans göstermiştir.

Attallah (100), COVID-19 tanısı için doku tabanlı radyomik özellikler ile derin öğrenmeyi birleştiren bir yöntem geliştirmiştir. ResNet modelleriyle çıkarılan özellikler SVM ile sınıflandırılmış ve SARS-CoV-2 BT veri setinde %99,6 doğruluk elde edilmiştir. Bu yaklaşım, orijinal görüntü tabanlı modellere göre daha iyi performans göstermiştir.

Veerappa (101), akciğer kanseri tespiti için bilgisayar destekli teşhis yöntemleri geliştirmiştir. Önerilen modelde, akciğer nodüllerinin segmentasyonu marker kontrollü watershed algoritması ile yapılmış; transfer öğrenme temelli hibrit özellik çıkarımıyla optimal katmanlar belirlenerek derin özellikler elde edilmiştir. Bu özellikler, başlıca bileşen analizi ile boyut indirgeme sonrası çeşitli makine öğrenmesi sınıflandırıcıları ile değerlendirilmiştir. Model, %94,21 genel doğruluk ile sınıflandırma, kesinlik, duyarlılık ve AUC değerlerinde mevcut yöntemlerin üzerinde performans göstermiştir.

Sharma ve ark. (102), tiroid nodülü tespiti için IoT tabanlı bir akıllı sağlık çerçevesi önermiştir. Araştırmada DeiT, Mixer-MLP ve Swin Transformer modelleriyle özellik çıkarımı yapılmış; mRMR ile önemli özellikler seçilmiştir. İyileştirilmiş Jaya optimizasyon algoritması kullanan ağırlıklı ortalama toplu öğrenme modeli; %92,83 doğruluk, %97,66 duyarlılık ve %88,89 özgüllük gibi yüksek performans metrikleri elde etmiştir. Model, yanlış pozitif oranını azaltarak hastaların gereksiz endişesini önlemeyi hedeflemekte ve güncel yöntemlere kıyasla üstün sonuçlar sunmaktadır.

Sengupta ve ark. (103), Subaraknoid kanama tespiti için DWSCSO tabanlı özellik seçimi ve PRSCNN sınıflandırma yöntemi geliştirmiştir. Model, kontrast madde kullanılmadan elde edilen bilgisayarlı tomografi görüntülerinden anlamlı öznitelikler seçerek %99,48 doğruluk oranıyla yüksek performans göstermiş ve yanlış pozitif ile yanlış negatif sonuçları azaltmıştır. Bu yöntem, mevcut yaklaşımlara kıyasla daha etkili sonuçlar sunmaktadır.

Ravi Kumar (104), pirinç yaprağı hastalıklarının erken tespiti ve çözüm önerileri için derin öğrenme tabanlı bir sistem geliştirmiştir. Çalışmada, pirinç yapraklarından oluşan özgün bir veri seti kullanılmıştır. VGG16 ile ResNet-50 mimarileri temel alan ESA modelleri uygulanmıştır. Bu yöntem, görüntü ön işleme ihtiyacını ortadan kaldırarak otomatik özellik seçimi sağlamış ve tarımda ürün kalitesi ve verimliliğin artırılmasına katkıda bulunmuştur.

Bandopadhyay ve ark. (105), beyin tümörü sınıflandırması için derin topluluk tabanlı özellik çıkarımı yöntemi geliştirmiştir. Çalışmada VGG16, ResNet50 ve Inception V3 modellerinden elde edilen derin özellikler birleştirilerek farklı makine öğrenmesi sınıflandırıcılarına beslenmiştir. İki MRI veri seti üzerinde gerçekleştirilen deneylerde, SVM sınıflandırıcısı BT-2 veri setinde %99, BT-4 veri setinde ise %94 doğruluk elde etmiştir. Bu yöntem, erken tanı ve tedavi sürecine katkı sağlamaktadır.

Çetintaş (106), Monkeypox virüsünün erken teşhisi için hibrit hafif ESA mimarileri ile optimize edilmiş SVM algoritmasını kullanan bir yöntem geliştirmiştir. MobileNetV3Large ve EfficientNetB0 modellerinin özellik çıkarımı ile birleştirildiği çalışmada, Grid Search ile parametre optimizasyonu sağlanmıştır. Monkeypox Skin Images ve Monkeypox Skin Lesion veri setlerinde çapraz doğrulama ile sırasıyla %98,67

ve %98,13 doğruluk elde edilmiştir. Bu yöntem, Monkeypox'un erken tespiti ve salgın önleme stratejilerinin geliştirilmesinde önemli bir katkı sunmaktadır.

Venkatraman ve Reddy (107), akciğer kanseri tanısında hızlı ve doğru tespit için VGG16 derin öğrenme modeli ile SVM'yi birleştiren hibrit bir yöntem önermiştir. IQ-OTH/NCCD veri seti üzerinde yapılan çalışmada agresif, iyi huylu ve normal kanser vakalarını ayırt etmede yüksek performans sergilemiştir. Bu yaklaşım, derin öğrenme ile geleneksel makine öğrenmesini bir araya getirerek tanı doğruluğu ve verimliliği konularında mevcut yöntemlere önemli katkılar sağlamaktadır. Çalışma ayrıca farklı mimarilerin karşılaştırmalı analizini yaparak doğruluk, verimlilik ve kaynak kullanımı açısından en uygun modeli belirlemiştir.

Madhavan ve ark. (108), metal üretiminde yüzey kusurlarının tespiti için derin öğrenme ve makine öğrenmesi tabanlı hibrit bir yöntem geliştirmiştir. Çalışmada, AlexNet, VGG16, VGG19, ResNet50, DenseNet201 ve GoogLeNet önceden eğitilmiş ağlarının son tam bağlantılı katmanlarından özellik çıkarımı yapılmıştır. Özellik seçimi için J48 karar ağacı algoritması kullanılmıştır. Bayes sınıflandırıcısıyla en iyi kombinasyon araştırılmıştır. DenseNet201'den çıkarılan özellikler ile fonksiyonel ağaç sınıflandırıcısının birleşimi %99,72 doğrulukla en yüksek performansı göstermiştir. Bu yöntem, sac metal kusur tespitinde hızlı, hassas ve etkili bir çözüm sunarak mevcut tekniklere kıyasla önemli ilerleme sağlamaktadır.

Basit ve ark. (109), Pakistan'daki enerji dağıtım sistemlerinde arıza tespiti için makine öğrenmesi destekli bir yaklaşım geliştirmiştir. İnsansız hava araçlarıyla toplanan 10.343 görüntü üzerinde denetimli (SVM, Random Forest, VGG16, ResNet50) ve denetimsiz otomatik kodlayıcı modeller uygulanmıştır. Deneylerde VGG16, %99 doğrulukla en iyi performansı gösterirken Random Forest, %72,49 ile en düşük doğruluğa ulaşmıştır. Otomatik kodlayıcı modeli ise normal ve anormal bileşenleri başarılı şekilde ayırt etmiştir. Önerilen yöntemler, insansız hava araçlarına entegre edilerek enerji hattı bileşenlerinin anlık olarak hatalı parçalarını tespit etmekte kullanılabilir.

Gupta ve ark. (110), MRI kullanarak beyin felci tahmini için IoT destekli derin öğrenme ve makine öğrenmesi modellerini karşılaştırmıştır. Çalışmada, MRI görüntüleri ön işleme tabi tutulmuş ve DenseNet-121, ResNet-50 ile VGG-16 gibi derin öğrenme yöntemleri uygulanmıştır. Ayrıca SVM ve karar ağaçları gibi makine öğrenmesi

yöntemleri ile performans karşılaştırması yapılmıştır. Sonuçlar, derin öğrenme modellerinin makine öğrenmesi modellerinden üstün olduğunu göstermiştir; özellikle DenseNet-121, %96 doğrulukla en başarılı sonucu elde etmiştir. ResNet-50 ve VGG16 ise sırasıyla %92 ve %81 doğruluk sağlamıştır. Bu çalışma, felç tahmininde derin öğrenmenin etkinliğini ortaya koymaktadır.

Öte taraftan VGG16 ve ResNet-50 kullanılarak elde edilen 2000 öznitelik içerisinden seçilen en belirgin özellikler SVM ve KNN sınıflandırılmıştır. Bulgular kısmında, seçilen 200 öznitelik ile en yüksek doğruluk değeri olarak %97 olarak elde edilmiştir. Bu tez çalışmasında kullanılan fMRMR öznitelik seçim algoritması ile veri setlerindeki gereksiz ve anlamsız öznitelikler elimine edilerek daha düşük boyutlu bir örnek alt kümesi elde edilmiştir. Literatürde fMRMR öznitelik seçim algoritması ile yapılan çalışmalar aşağıda verilmiştir.

Togacar ve ark. (111), akciğer X-ray görüntülerinden zatürre tespiti için AlexNet, VGG-16 ve VGG-19 tabanlı bir yaklaşım geliştirmiştir. MRMR algoritmasıyla öznitelik boyutu azaltılmış ve farklı makine öğrenmesi yöntemleri denenmiştir. Lineer diskriminant analizi %99,41 doğrulukla en iyi sonucu vermiştir. Çalışma, derin özniteliklerin zatürre teşhisinde güçlü bir temsil sunduğunu göstermektedir.

Jo ve ark. (112), biyolojik ve tıbbi verilerde öznitelik seçimi için mRMR yöntemini geliştirmiştir. Çalışmada, fazlalık ölçümünde Pearson korelasyonu, alaka ölçümünde ise R değeri kullanılarak daha etkili bir seçim yöntemi önerilmiştir. Farklı veri kümelerinde yapılan sınıflandırma testlerinde, önerilen yöntem klasik mRMR'a kıyasla daha yüksek doğruluk oranları elde etmiştir. Bu yaklaşım, özellikle karmaşık veri kümelerinde sınıflandırma başarısını artırmak için önemli bir katkı sunmaktadır.

Cai ve ark. (113), lizin amino asidi üzerindeki ubikitinasyon bölgelerini tahmin etmek için en yakın komşu algoritmasına dayalı bir yöntem geliştirmiştir. Hızlı minimum fazlalık ve maksimum alaka prensipleri kullanılarak 456 önemli öznitelik seçilmiş ve model optimize edilmiştir. Bağımsız testlerde, önerilen yöntem 0,139 Mathew's korelasyon katsayısıyla UbiPred ve UbPred yöntemlerinden daha iyi performans göstermiştir. Çalışma, lizin çevresindeki amino asitlerin korunumu ve protein düzensizliğinin ubikitinasyon tahmininde önemli etkileri olduğunu göstermektedir.

Wang ve ark. (114), kalp hastalıklarının teşhisinde yapay zekâ destekli yaklaşımlar üzerine çalışmıştır. Kaliforniya Üniversitesi, veri kümesindeki işlenmemiş 74 özellikli veri setinin, işlenmiş 13 özellikli veri setinden daha faydalı olduğunu göstermiştir. MRMR yöntemiyle yapılan öznitelik seçimi, Principal Component Analysis, Linear Discriminant Analysis ve Random Forest gibi yöntemlere kıyasla daha yüksek doğruluk ve daha az gereksiz özellik sağlamıştır. Önerilen yöntem; Cleveland, Hungarian ve Long-beach-VA veri setlerinde %98–%100 arası doğruluk elde etmiştir.

Hermo ve ark. (115), veri gizliliğinin kritik olduğu dağıtık ve heterojen ortamlarda öznitelik seçimi yapmak için klasik mRMR algoritmasının kayıpsız federatif versiyonu olan fed-mRMR'yi geliştirmiştir. Bu yöntem, merkezî sunucuya veri gönderilmeden, farklı cihazlardaki yerel veriler üzerinde işleyerek hem hesaplama verimliliğini artırmakta hem de orijinal mRMR'nin doğruluk ve etkinliğini korumaktadır. Fed-mRMR, özellikle bağımsız ve aynı dağılıma sahip olmayan verilerle çalışan federatif öğrenme senaryolarında güvenli ve etkili öznitelik seçimi sağlamaktadır. Bu çalışma; sağlık, otonom araçlar ve Endüstri 4.0 gibi gizlilik hassasiyeti yüksek alanlarda federatif öznitelik seçiminin uygulanabilirliğine önemli katkılar sunmaktadır.

Sathishkumar ve Cho (116), regresyon problemlerinde performansı artırmak amacıyla filtre ve sarmalayıcı yöntemlerin hibritini kullanan bir öznitelik seçimi algoritması geliştirmiştir. MRMR ile Elephant Herding Optimization yöntemini birleştiren model çeşitli veri setlerinde CUBIST ve diğer regresyon algoritmalarının başarısını artırmıştır. Çalışma küçük ve büyük ölçekli veri kümelerinde öngörücü modelleme için etkili bir araç olduğunu göstermektedir.

Niu ve ark. (117), protein tirozin sülfasyon bölgelerinin tahmini için en yakın komşu algoritması ile mMRMR yöntemini kullanmıştır. Toplam 229 özellikten 145'i seçilerek optimize edilen model %90,01 doğruluk elde etmiştir. Çalışma, amino asitlerin korunumu, düzensizliği ve fiziko-kimyasal özelliklerinin sülfasyon sürecinde önemli rol oynadığını göstermiştir. Ayrıca, sülfasyon bölgesinin çevresindeki özelliklerin tahminde belirleyici olduğu vurgulanmıştır.

Özyurt (118), beyaz kan hücresi sınıflandırması için AlexNet, VGG-16, GoogleNet ve ResNet önceden eğitilmiş modellerinden çıkarılan özellikleri

birleştirmiştir. MRMR yöntemiyle seçilen verimli özellikler, sınıflandırma için Extreme Learning Machine algoritmasına verilmiştir. Önerilen yöntem %96,03 doğruluk oranı ve kısa çalışma süresiyle başarılı sonuçlar elde etmiştir.

Yan ve Jia (119), dönen makinelerde arıza tanısı için geliştirdikleri yöntemde, orijinal titreşim sinyalinden çok ölçekli özellikleri çıkarmak üzere geliştirilmiş, çok ölçekli dağılım entropisi yöntemini kullanmıştır. Daha sonra, mRMR algoritması ile en duyarlı özellikler otomatik olarak seçilmiştir. Seçilen özellikler normalize edilip Aşırı Öğrenme Makinesi sınıflandırıcısına verilerek arıza tespiti yapılmıştır. Önerilen yöntem, rulman ve dişli kutusu arızalarının tanısında geleneksel çok ölçekli entropi yöntemlerine kıyasla daha yüksek doğruluk sağlamıştır. Çalışma, titreşim sinyalinden arıza bilgisi çıkarımı ve sınıflandırmada yenilikçi bir yaklaşım sunmaktadır.

Jin ve ark. (120), elektronik ürünlerde soğutma fanlarının sağlık durumunu izlemek ve arıza tespiti yapmak için Mahalanobis mesafesi ve mRMR özelliklerine dayalı yeni bir yöntem önermiştir. Bu yöntem, çoklu bağlantılılık sorununu önlerken fanların bozulma eğilimlerini takip etmeye olanak sağlamaktadır. Önerilen yaklaşım, yapılan vaka çalışmasında uygulanabilir ve etkili bulunmuştur.

Rachburee ve Punlumjeak (121), öğrenci performansını tahmin etmeye yönelik bir çalışmada greedy algoritma, bilgi kazancı oranı, ki-kare ve mRMR olmak üzere dört farklı öznitelik seçme yöntemini kullanarak dört ayrı sınıflandırma modelinin başarılarını karşılaştırmıştır. 6.882 mühendislik öğrencisinin verileri kullanılarak yapılan deneylerde, greedy ileri seçimin YSA sınıflandırmasıyla %91,16 doğrulukla en iyi performansı sağladığı gösterilmiştir. Çalışma, öznitelik seçiminin öğrenci başarısı tahmininde etkinliğini ortaya koymaktadır.

Idris ve ark. (122), telekomünikasyon sektöründe müşteri kaybı tahmini için mRMR tabanlı öznitelik seçimi ile RotBoost topluluk yöntemini bir arada kullanmıştır. MRMR, Fisher oranı ve F-skoruna kıyasla en açıklayıcı öznitelikleri seçerek hesaplama maliyetlerini azaltmış ve sınıflandırıcıların performansını artırmıştır. RotBoost algoritması, özellik uzayının rotasyonu sayesinde müşteri kaybeden ve kaybetmeyen grupların farklı yönlerini öğrenmiş, Adaboosting mekanizmasıyla da zor örneklerin sınıflandırılmasında başarı sağlamıştır. Standart telekom veri setlerinde AUC, duyarlılık

ve özgüllük metrikleriyle değerlendirilen yöntem, yüksek boyutlu veri kümelerinde etkili sonuçlar vererek müşteri kaybı tahmininde güçlü bir çözüm sunmaktadır.

Hu ve ark. (123), mekanik bileşenlerin arıza teşhisi için geleneksel boyutsuz göstergelerin doğruluk sorunlarını aşmak amacıyla yeniden tanımlanmış boyutsuz göstergeler mRMR tabanlı bir yöntem önermiştir. İlk olarak titreşim sinyalleri varyasyonel mod ayrıştırması ile işlenmiş, ardından oluşturulan çoklu RDIs mRMR ile seçilmiştir. Seçilen önemli RDIs, Grid Search SVM verilerek arıza tipleri tanımlanmıştır. Rulman ve dişli kutusu üzerindeki deneylerde, önerilen yöntem 12 rulman arızasını %97,47, 9 dişli arızasını ise %97,12 doğrulukla ayırt etmiştir. Çalışma, yeniden tanımlanmış boyutsuz göstergelerin arıza teşhisinde geleneksel yöntemlere kıyasla üstün ayırt edici güç sağladığını göstermektedir.

Li ve ark. (124), planet dişli kutularının sağlık durumlarını belirlemek için modifiye edilmiş, çok ölçekli sembolik dinamik entropi ve mRMR tabanlı yeni bir arıza teşhis yöntemi geliştirmiştir. Bu yöntem, zaman serilerinin dinamik özelliklerini çoklu ölçeklerde değerlendirerek düzenlilik ve dinamik değişimleri etkin şekilde yakalamaktadır. MRMR yöntemi ise önemli arıza özelliklerini seçmek için kullanılmıştır. Seçilen özellikler, en küçük kareler destek vektör makineleri ile sınıflandırılarak farklı arıza tipleri başarıyla tanımlanmıştır. Hem sayısal hem de deneysel çalışmalarda yöntem etkinliği doğrulanmıştır.

Bansal ve ark. (125), işaret dili tanıma için çok amaçlı hibrit bir öznitelik seçimi yöntemi olan mRMR-Parçacık Sürüsü Optimizasyonunu önermiştir. Giriş jestleri için Yönlendirilmiş Gradyan Histogramı algoritması ile özellikler çıkarılmıştır. İlerleyen aşamalarda mRMR ile gereksiz ve fazlalık içeren özellikler temizlenerek Parçacık Sürüsü Optimizasyonu algoritmasının hesaplama yükü azaltılmıştır. Parçacık Sürüsü Optimizasyonu, sınıflandırıcı performansına göre en yüksek doğruluk ve en az özellik sayısını sağlayan öznitelik alt kümesini seçmiştir. Çok sınıflı SVM kullanılarak yapılan sınıflandırmada, önerilen yöntem yedi farklı işaret dili veri setinde hem basit hem de karmaşık arka planlarda üstün doğruluk ve daha küçük özellik vektörü boyutu elde etmiştir. Friedman testi ile mRMR-Parçacık Sürüsü Optimizasyonu'nun diğer yöntemlere kıyasla anlamlı üstünlüğü doğrulanmıştır.

Wu ve ark. (126), hava kalitesi indeksini tahmin etmek için random forest, mRMR tabanlı özellik seçimi ve Geliştirilmiş Sincap Arama Algoritmasını kullanarak modeli geliştirmiştir. Çalışmada Rastgele Orman–mRMR yöntemi, hava kalitesi üzerinde etkili değişkenleri belirleyerek modelin öngörü gücünü artırırken Geliştirilmiş Sincap Arama Algoritması, Uzun-Kısa Vadeli Bellek modelinin hiperparametrelerini optimize ederek genel performansı iyileştirmiştir. Bu birleşim, farklı zaman adımlarında yapılan testlerde diğer modellere kıyasla daha düşük hata ve daha yüksek açıklayıcılık sunmuş, böylece hava kalitesi indeksi tahmininde yüksek doğruluk sağlamıştır. Önerilen Geliştirilmiş Sincap Arama Algoritması–Uzun-Kısa Vadeli Bellek modeli, hava kirliliği tahmininde etkili ve güvenilir bir yaklaşım olarak kabul edilmektedir.

Ren ve ark. (127), karmaşık arka planlarda küçük hedeflerin tanımlanması için derin öğrenmeye dayalı bir öznitelik seçimi yöntemi geliştirmiştir. YOLOv5 sinir ağı kullanılarak tam bağlı katmandan çıkarılan 512 aday özellik, mRMR algoritması ile yüksek korelasyonlu fazlalıklardan arındırılarak özellik setinin boyutu azaltılmıştır. Ayrıca, görüntü ön işleme adımları ile tanıma doğruluğu artırılmıştır. Deneysel sonuçlar, mRMR'nin öznitelik boyutunu etkili şekilde düşürerek küçük hedeflerin tanımlanmasında başarı sağladığını göstermektedir.

Jiang ve Li (128), pamuk yabancı maddelerinin sınıflandırılması için hiperspektral görüntüleme verilerinden optimal dalga boylarını seçmek amacıyla mRMR tabanlı iki aşamalı bir öznitelik seçimi yöntemi geliştirmiştir. Çalışmada, 400-1000 nm aralığında 256 dalga boyuna sahip 480 örnek içeren bir spektral veri seti kullanılmış, ön işlemle gürültülü dalga boyları çıkarılmıştır. MRMR algoritması ile ilk aşamada yüksek dereceli özellikler sıralanmış, ardından ardışık geriye eleme yöntemiyle optimal 12 dalga boyu seçilmiştir. Seçilen dalga boylarının çoğunluğu görünür ve yakın kızılötesi bölgelerde olup yabancı madde pigmentleri ve protein/nutrient içerikleriyle ilişkilendirilmiştir. Bu dalga boyları; SVM ve YSA gibi farklı sınıflandırıcılarla %86'nın üzerinde doğruluk oranları elde ederek seçilen özniteliklerin genellenebilirliğini göstermiştir. Çalışma, hiperspektral görüntülemede etkili dalga boyu seçimi için yeni bir yöntem sunmaktadır.

Peker ve ark. (129), Parkinson hastalığının otomatik teşhisi için biyomedikal ses ölçümlerini kullanan yeni bir yöntem geliştirmiştir. Sürekli fonasyon örneklerinden elde edilen verilerle mRMR algoritması etkili öznitelikleri seçmek için uygulanmıştır. Seçilen özellikler karmaşık sayıya dönüştürülerek karma değerli YSA'ya giriş olarak verilmiştir.

Önerilen sistem, Parkinson hastalığının özellikle erken evrelerinde daha hızlı ve etkili teşhis yapılmasına olanak sağlayan güçlü bir araç olarak değerlendirilmektedir.

6. SONUÇLAR

Bu tez çalışmasında, tıbbi cihazların yapay zekâ tabanlı algoritmalarla sınıflandırılması ele alınmış ve elde edilen sonuçların sağlık hizmetlerinde biyomedikal envanter yönetimine katkısı değerlendirilmiştir. Çalışmada, Medikal Cihaz 5 veri kümesi kullanılarak beş farklı türde tıbbi cihazın sınıflandırılması gerçekleştirilmiştir. Önerilen yöntem ile %96,29 genel doğruluk oranı elde edilerek yüksek bir sınıflandırma performansı sağlanmıştır. Derin öğrenme modelleriyle elde edilen en yüksek doğruluk oranı %94,18 iken öznitelik seçimi yöntemi sayesinde bu değer %96,29'a yükselmiştir.

Ayrıca, yapay zekâ destekli tıbbi cihaz sınıflandırmasına yönelik literatür taraması yapılmıştır ve bu çalışmanın literatürde bu alana yönelik ilk örnek olduğu belirlenmiştir.

Medikal Cihaz 5 veri seti, tıbbi cihaz alanında yapay zekâ çalışmalarını desteklemek amacıyla oluşturulmuştur ancak veri seti beş sınıfla sınırlıdır. Medikal Cihaz 5 veri setinde sınıflar arası dengesiz örnek dağılımları mevcuttur. Bu durum aşırı öğrenme problemine neden olmaktadır. Çalışmada bu zorluğun üstesinden gelmek için veri artırma teknikleri kullanılmıştır.

Bu tez çalışması ile elde edilen yapay zekâ modeli sağlık tesislerinde envanter yönetimi için kullanılan yazılımlara entegre olarak çalışabilecek niteliktedir. Geliştirilen model sağlık tesislerinde biyomedikal departmanlarında, envanter yönetim birimlerinde ve hastane kliniklerinde görev yapan sağlık profesyonelleri tarafından kullanılarak etkin ve kaliteli bir sağlık sunumunu sağlayacaktır.

Bu çalışma ile bilhassa yeterli biyomedikal personeli tahsis edilemeyen kırsal bölgelerde biyomedikal birimler tarafından yürütülmesi gereken envanter yönetimi daha etkin şekilde sağlanacaktır. Güncel envanter bilgisine sahip sağlık tesisleri tıbbi cihaz bakım, onarım ve yönetiminde hızlı aksiyon alabilecektir.

Çalışmada Medikal Cihaz 5 veri kümesi üzerinde yürütülen deneyler, yapay zekâ algoritmalarının tıbbi cihaz sınıflandırma görevlerinde yüksek başarı sağlayabileceğini ortaya koymuştur. Elde edilen bulguların, yapay zekâ destekli sistemler aracılığıyla biyomedikal süreçlere ilişkin sorunlara daha etkin ve kalıcı çözümler sunması öngörülmektedir. Özellikle manuel ve hataya açık olarak yürütülen biyomedikal cihaz süreçlerinin yapay zekâ tabanlı algoritmalarla hızlı ve hatadan arındırılmış olarak

sunulacak çözümler sağlık hizmet kalitesini artıracaktır. Bu tez çalışmasında sonuçları sunulan Medical Device 5 veri setinde yer alan cihaz türleri, sağlık tesislerinde en sık kullanılan ekipmanlar arasından seçilmiştir. Bununla birlikte, gelecekte daha fazla cihaz sınıfını ve örnek sayısını kapsayacak biçimde güncellenmiş ve genişletilmiş veri setlerine ihtiyaç duyulmaktadır. Bu kapsamlı veri setleri, güncel yapay zekâ modelleri ile kullanılabilir. Bu sayede cihaz görüntü sınıflandırması ve cihaz envanter takibi süreci daha da kolaylaşabilir. İlerleyen çalışmalarda bu uygulamaların, içerik tabanlı görüntü geri getirme sistemleri ile entegre edilerek geliştirilmesi, yenilikçi biyomedikal sağlık hizmetlerinin tasarlanmasına ve uygulanmasına önemli ölçüde katkı sağlayacaktır.

KAYNAKLAR

1. Leibowitz AA. The demand for health and health concerns after 30 years. Journal of Health Economics. 2004;23(4):663-71.
2. Bronzino JD. Medical devices and systems: CRC press; 2006.
3. Geller J. FDA Approves Variety of Medical Devices. Journal of Clinical Engineering. 2015;40(1):4-9.
4. Kılıçarslan M, Takkasız B. Dünyada ve Türkiye'de tıbbi cihaz sektöründe pazarlamanın önemi. Avrupa Bilim ve Teknoloji Dergisi. 2019(17):966-71.
5. Sherwin J. The essentials of medical device inventory tracking. Biomedical Instrumentation & Technology. 2013;47(5):382-6.
6. Koçak O, Koçoğlu A, Telatar Z, Eroğul O. Türkiye'de Biyomedikal Mühendisliği Eğitimi, Uygulamaları ve İstihdam Zorunluluğu. Elektrik Elektronik Bilgisayar Biyomedikal Mühendislikleri Eğitimi Ulusal Sempozyumu. 2009:22-4.
7. Bektemür G, Muzoğlu N, Arıcı MA, Karaaslan MK. Medikal cihaz teknolojilerinin maliyet etkili yönetimi ve klinik mühendislik departmanlarının rolü. Sağlık Akademisyenleri Dergisi. 2018;5(3):184-91.
8. Abdikhakimov I. Harnessing the Power of Big Data: Opportunities, Challenges, and Best Practices. Research and Publication. 2023;1(1):96-101.
9. Winston PH. Artificial intelligence: Addison-Wesley Longman Publishing Co., Inc.; 1992.
10. Mitchell TM, Mitchell TM. Machine learning: McGraw-hill New York; 1997.
11. LeCun Y, Bengio Y, Hinton G. Deep learning. nature. 2015;521(7553):436-44.
12. Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: analysis, applications, and prospects. IEEE transactions on neural networks and learning systems. 2021;33(12):6999-7019.
13. Maisel WH. Medical device regulation: an introduction for the practicing physician. Annals of internal medicine. 2004;140(4):296-302.
14. Toennies JL, Tortora G, Simi M, Valdastri P, Webster R. Swallowable medical devices for diagnosis and surgery: the state of the art. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science. 2010;224(7):1397-414.
15. Belova I, Dyatlova M. World medical devices market: current trends and their realization in Russia. Economic Annals-XXI/Ekonomìčnij Časopis-XXI. 2020;183.
16. Organization WH. Medical devices: managing the mismatch: an outcome of the priority medical devices project: World Health Organization; 2010.
17. Arık Ö, İleri YY, Kaya B. Sağlık hizmetlerinde tıbbi cihaz sektörü. Hacettepe Sağlık İdaresi Dergisi. 2016;19(2).
18. Heathfield H, Pitty D, Hanka R. Evaluating information technology in health care: barriers and challenges. Bmj. 1998;316(7149):1959.
19. Magretta J. What management is: Simon and Schuster; 2002.
20. Cheng M. Medical device regulations: global overview and guiding principles. 2003.
21. Yenice E. PERFORMANS DENETİMİ VE TÜRKİYE UYGULAMASI. KAMU MALİ YÖNETİMİNDE STRATEJİK PLANLAMA VE PERFORMANS ESASLI BÜTÇELEME. 2006:161.
22. SELVİ Y. SAĞLIK KURULUŞLARINDA TIBBİ CİHAZ YÖNETİMİ.
23. Cüneyitoğlu Özkul M, Mumcuoğlu ÜE. Biyomedikal Mühendisliği ve Uygulamaları. TMMOB, EMO Ankara Şubesi; 2019.
24. Coşkun Ö, Çömlekçi S. Biyomedikal mühendislik hizmetlerinin hastanelerdeki rolü. Teknik Bilimler Dergisi. 2011;1(1):23-8.
25. Hillstrom NL, Malabanan RA. Strategic inventory management of externally sourced medical devices: Massachusetts Institute of Technology; 2013.
26. Leaven L, Ahmmad K, Peebles D. Inventory management applications for healthcare supply chains. International Journal of Supply Chain Management. 2017;6(3):1-7.
27. Dorsch JA. Understanding anesthesia equipment: Lippincott Williams & Wilkins; 2012.
28. Smallheer BA. Technology and monitoring patients at the bedside. Nurs Clin North Am. 2015;50(2):257-68.
29. El-Shorbagy A-m. Design with nature: windcatcher as a paradigm of natural ventilation device in buildings. International Journal of Civil & Environmental Engineering IJCEE-IJENS. 2010;10(03):26-31.

30. Tamber KK, Hayes DJ, Carey SJ, Wijekoon JH, Heazell AE. A systematic scoping review to identify the design and assess the performance of devices for antenatal continuous fetal monitoring. PloS one. 2020;15(12):e0242983.
31. Gregg RE, Zhou SH, Lindauer JM, Helfenbein ED, Giuliano KK. What is inside the electrocardiograph? Journal of electrocardiology. 2008;41(1):8-14.
32. Hunt EB. Artificial intelligence: Academic Press; 2014.
33. Alpaydin E. Machine learning: MIT press; 2021.
34. Castelvecchi D. Can we open the black box of AI? Nature News. 2016;538(7623):20.
35. Schwalbe N, Wahl B. Artificial intelligence and the future of global health. The Lancet. 2020;395(10236):1579-86.
36. Ghaffar Nia N, Kaplanoglu E, Nasab A. Evaluation of artificial intelligence techniques in disease diagnosis and prediction. Discover Artificial Intelligence. 2023;3(1):5.
37. Attia ZI, Kapa S, Noseworthy PA, Lopez-Jimenez F, Friedman PA, editors. Artificial intelligence ECG to detect left ventricular dysfunction in COVID-19: a case series. Mayo clinic proceedings; 2020: Elsevier.
38. Weisberg EM, Chu LC, Fishman EK. The first use of artificial intelligence (AI) in the ER: triage not diagnosis. Emergency Radiology. 2020;27:361-6.
39. Wang J, Zeng Z, Li Z, Liu G, Zhang S, Luo C, et al. The clinical application of artificial intelligence in cancer precision treatment. Journal of Translational Medicine. 2025;23(1):120.
40. Kibudde S, Kavuma A, Hao Y, Zhao T, Gay H, Van Rheenen J, et al. Impact of artificial intelligence-based autosegmentation of organs at risk in low-and middle-income countries. Advances in Radiation Oncology. 2024;9(11):101638.
41. Ohno S, Manabe N, Yamaguchi Y. Prediction of protein structure and AI. Journal of Human Genetics. 2024;69(10):477-80.
42. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. Nature medicine. 2022;28(1):31-8.
43. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJ. Artificial intelligence in radiology. Nature Reviews Cancer. 2018;18(8):500-10.
44. McKinney SM, Sieniek M, Godbole V, Godwin J, Antropova N, Ashrafian H, et al. International evaluation of an AI system for breast cancer screening. Nature. 2020;577(7788):89-94.
45. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. nature. 2017;542(7639):115-8.
46. Stokes JM, Yang K, Swanson K, Jin W, Cubillos-Ruiz A, Donghia NM, et al. A deep learning approach to antibiotic discovery. Cell. 2020;180(4):688-702. e13.
47. Morales EF, Escalante HJ. A brief introduction to supervised, unsupervised, and reinforcement learning. Biosignal processing and classification using computational learning and intelligence: Elsevier; 2022. p. 111-29.
48. Nasteski V. An overview of the supervised machine learning methods. Horizons b. 2017;4(51-62):56.
49. Naeem S, Ali A, Anam S, Ahmed MM. An unsupervised machine learning algorithms: Comprehensive review. International Journal of Computing and Digital Systems. 2023.
50. François-Lavet V, Henderson P, Islam R, Bellemare MG, Pineau J. An introduction to deep reinforcement learning. Foundations and Trends® in Machine Learning. 2018;11(3-4):219-354.
51. Kumar V, Minz S. Feature selection. SmartCR. 2014;4(3):211-29.
52. Radovic M, Ghalwash M, Filipovic N, Obradovic Z. Minimum redundancy maximum relevance feature selection approach for temporal gene expression data. BMC bioinformatics. 2017;18:1-14.
53. Goodfellow I, Bengio Y, Courville A, Bengio Y. Deep learning: MIT press Cambridge; 2016.
54. Taye MM. Understanding of machine learning with deep learning: architectures, workflow, applications and future directions. Computers. 2023;12(5):91.
55. Dongare A, Kharde R, Kachare AD. Introduction to artificial neural network. International Journal of Engineering and Innovative Technology (IJEIT). 2012;2(1):189-94.
56. Wu Y-c, Feng J-w. Development and application of artificial neural network. Wireless Personal Communications. 2018;102:1645-56.
57. Da Silva IN, Hernane Spatti D, Andrade Flauzino R, Liboni LHB, dos Reis Alves SF, da Silva IN, et al. Artificial neural network architectures and training processes: Springer; 2017.
58. Cong S, Zhou Y. A review of convolutional neural network architectures and their optimizations. Artificial Intelligence Review. 2023;56(3):1905-69.
59. Dogo EM, Afolabi O, Nwulu N, Twala B, Aigbavboa C, editors. A comparative analysis of gradient descent-based optimization algorithms on convolutional neural networks. 2018 international conference on computational techniques, electronics and mechanical systems (CTEMS); 2018: IEEE.

60. Torrey L, Shavlik J. Transfer learning. Handbook of research on machine learning applications and trends: algorithms, methods, and techniques: IGI global; 2010. p. 242-64.
61. Pan SJ. Transfer learning. Learning. 2020;21:1-2.
62. Flach, P. (2019, July). Performance evaluation in machine learning: the good, the bad, the ugly, and the way forward. In Proceedings of the AAAI conference on artificial intelligence (Vol. 33, No. 01, pp. 9808-9814).
63. Wu, B., Pang, C., Zeng, X., & Hu, X. (2022). ME-YOLO: Improved YOLOv5 for detecting medical personal protective equipment. Applied Sciences, 12(23), 11978.
64. Moktar, M. H., Mohamed, H., Hajjaj, S. S. H., & Baharuddin, M. Z. (2025). Medical waste sorting machine development with IoT and YOLO model utilization. Journal of Engineering and Applied Science, 72(1), 1-25.
65. Ceross A, Bergmann J, editors. A machine learning approach for medical device classification. Proceedings of the 14th International Conference on Theory and Practice of Electronic Governance; 2021.
66. Kumar Y, Gupta S, Gupta A, editors. Study of machine and deep learning classifications for IoT enabled healthcare devices. 2021 International Conference on Technological Advancements and Innovations (ICTAI); 2021: IEEE.
67. Kovačević Ž, Gurbeta Pokvić L, Spahić L, Badnjević A. Prediction of medical device performance using machine learning techniques: infant incubator case study. Health and Technology. 2020;10(1):151-5.
68. Rowan NJ, Kremer T, McDonnell G. A review of Spaulding's classification system for effective cleaning, disinfection and sterilization of reusable medical devices: Viewed through a modern-day lens that will inform and enable future sustainability. Science of The Total Environment. 2023;878:162976.
69. Spahić L, Kurta E, Ćordić S, Bećirović M, Gurbeta L, Kovacevic Z, et al., editors. Machine learning techniques for performance prediction of medical devices: infant incubators. International Conference on Medical and Biological Engineering; 2019: Springer.
70. Zhou H, Yu X, Alhaskawi A, Dong Y, Wang Z, Jin Q, et al. A deep learning approach for medical waste classification. Scientific reports. 2022;12(1):2159.
71. Moktar MHB, Hajjaj SSH, Mohamed H, editors. Medical Waste Detection and Classification Through YOLO Algorithms. International Conference on Robot Intelligence Technology and Applications; 2023: Springer.
72. Ahmed Z, Shanto SS. Performance Analysis of YOLO Architectures for Surgical Waste Detection in Post-COVID-19 Medical Waste Management. Malaysian Journal of Science and Advanced Technology. 2024:1-9.
73. Hidayat MF, Suakanto S, Hamami F, Raffei AFM, Nuryatno E, editors. Object Detection for Occluded Medical Equipment in Hospital Environments Using YOLOv8. 2025 International Conference on Advancement in Data Science, E-learning and Information System (ICADEIS); 2025: IEEE.
74. Pan X, Bi M, Wang H, Ma C, He X. DBH-YOLO: a surgical instrument detection method based on feature separation in laparoscopic surgery. International Journal of Computer Assisted Radiology and Surgery. 2024;19(11):2215-25.
75. Ding H, Huang N, Wu Y, Cui X. Improving imbalanced medical image classification through GAN-based data augmentation methods. Pattern Recognition. 2025;166:111680.
76. Beddiar DR, Oussalah M, Muhammad U, Seppänen T. A deep learning based data augmentation method to improve COVID-19 detection from medical imaging. Knowledge-Based Systems. 2023;280:110985.
77. Zhang H, Huang Z, Lv Z, editors. Medical image synthetic data augmentation using GAN. Proceedings of the 4th International Conference on Computer Science and Application Engineering; 2020.
78. Mikołajczyk A, Grochowski M, editors. Data augmentation for improving deep learning in image classification problem. 2018 international interdisciplinary PhD workshop (IIPhDW); 2018: IEEE.
79. Abdollahi B, Tomita N, Hassanpour S. Data augmentation in training deep learning models for medical image analysis. Deep learners and deep learner descriptors for medical applications. 2020:167-80.
80. Liu X, Karagoz G, Meratnia N. Analyzing the Impact of Data Augmentation on the Explainability of Deep Learning-Based Medical Image Classification. Machine Learning and Knowledge Extraction. 2024;7(1):1.
81. Chen H, Cao P, editors. Deep learning based data augmentation and classification for limited medical data learning. 2019 IEEE international conference on power, intelligent computing and systems (ICPICS); 2019: IEEE.
82. Rais K, Amroune M, Haouam MY, Bendib I, editors. Comparative study of data augmentation approaches for improving medical image classification. 2023 International Conference on Computational Science and Computational Intelligence (CSCI); 2023: IEEE.

83. Qi C, Chen J, Xu G, Xu Z, Lukasiewicz T, Liu Y. SAG-GAN: Semi-supervised attention-guided GANs for data augmentation on medical images. arXiv preprint arXiv:201107534. 2020.
84. Huang P, Liu X, Huang Y. Data augmentation for medical MR image using generative adversarial networks. arXiv preprint arXiv:211114297. 2021.
85. Llambias SN, Nielsen M, Ghazi MM. Data augmentation-based unsupervised domain adaptation in medical imaging. arXiv preprint arXiv:230804395. 2023.
86. Safdar MF, Alkobaisi SS, Zahra FT. A comparative analysis of data augmentation approaches for magnetic resonance imaging (MRI) scan images of brain tumor. Acta informatica medica. 2020;28(1):29.
87. Liu H, Cao H, Song E, Ma G, Xu X, Jin R, et al. A new data augmentation method based on local image warping for medical image segmentation. Medical Physics. 2021;48(4):1685-96.
88. He X, Chu X, editors. Medpipe: End-to-end joint search of data augmentation and neural architecture for 3d medical image classification. 2023 IEEE International Conference on Medical Artificial Intelligence (MedAI); 2023: IEEE.
89. Mikołajczyk, A., & Grochowski, M. (2018, May). Data augmentation for improving deep learning in image classification problem. In 2018 international interdisciplinary PhD workshop (IIPhDW) (pp. 117-122). IEEE.
90. Zhao A, Balakrishnan G, Durand F, Guttag JV, Dalca AV, editors. Data augmentation using learned transformations for one-shot medical image segmentation. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition; 2019.
91. Taşci B. Deep Learning-Based Approaches Using Feature Selection Methods for Automatic Diagnosis of COVID-19 Disease from X-Ray Images. Deep Learning Applications in Image Analysis: Springer; 2023. p. 27-50.
92. Özyurt F. Efficient deep feature selection for remote sensing image recognition with fused deep learning architectures. The Journal of Supercomputing. 2020;76(11):8413-31.
93. Nijaguna G, Babu JA, Parameshachari B, de Prado RP, Frnda J. Quantum Fruit Fly algorithm and ResNet50-VGG16 for medical diagnosis. Applied Soft Computing. 2023;136:110055.
94. Velpula VK, Reddy KR, Prakash KN, Jasmine KP, Jyothi Sri V. Optimizing Brain Tumor Classification: Integrating Deep Learning and Machine Learning with Hyperparameter Tuning. Engineering Proceedings. 2025;87(1):64.
95. Bhalaji Kharthik K, Onyema EM, Mallik S, Siva Prasad B, Qin H, Selvi C, et al. Transfer learned deep feature based crack detection using support vector machine: a comparative study. Scientific reports. 2024;14(1):14517.
96. Yaman S, Ünlü EI, Güler H, Sengur A, Acharya UR. Application of novel DIRF feature selection algorithm for automated brain disease detection. Biomedical Signal Processing and Control. 2023;85:105006.
97. Danaci C, Avci D, Tuncer SA. Diagnosis of pes planus from X-ray images: Enhanced feature selection with deep learning and machine learning techniques. Biomedical Signal Processing and Control. 2025;106:107769.
98. Attallah O, Samir A. A wavelet-based deep learning pipeline for efficient COVID-19 diagnosis via CT slices. Applied Soft Computing. 2022;128:109401.
99. Malik S, Amin J, Sharif M, Yasmin M, Kadry S, Anjum S. Fractured elbow classification using hand-crafted and deep feature fusion and selection based on whale optimization approach. Mathematics. 2022;10(18):3291.
100. Attallah O. A computer-aided diagnostic framework for coronavirus diagnosis using texture-based radiomics images. Digital Health. 2022;8:20552076221092543.
101. Mothkur R, Veerappa B. A Robust Approach for Segmentation and Classification of Lung Cancer using Marker Controlled Watershed Method and Deep Hybrid Learning.
102. Sharma R, Mahanti GK, Chakraborty C, Panda G, Rath A. An IoT and deep learning-based smart healthcare framework for thyroid cancer detection. ACM Transactions on Internet Technology. 2023.
103. Sengupta J, Alzbutas R, Iešmantas T, Petkus V, Barkauskienė A, Ratkūnas V, et al. Detection of Subarachnoid Hemorrhage Using CNN with Dynamic Factor and Wandering Strategy-Based Feature Selection. Diagnostics. 2024;14(21):2417.
104. Kumar R, Vedavathi K, Dhanusha K, Yadav MG, Chowdary KV, Tej S. Rice Leaf Disease Detection and Remedies Recommendation Using Deep Learning. 2023.
105. Bandopadhyay S, Shaw R, Chowdhury JR, Gupta S, Ashish K, Banerjee S, editors. Deep Ensemble Feature Extraction based Classification of Brain Tumor using MRI Images. 2024 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI); 2024: IEEE.

106. Çetintaş D. Efficient monkeypox detection using hybrid lightweight CNN architectures and optimized SVM with grid search on imbalanced data. Signal, Image and Video Processing. 2025;19(4):1-12.
107. Venkatraman K, Reddy SNPS, editors. Augmenting Clinical Decisions with Deep Learning Lung Cancer Image Abnormality Segmentation. 2024 14th International Conference on Cloud Computing, Data Science & Engineering (Confluence); 2024: IEEE.
108. Madhavan S, Sridharan NV, Mahanta TK, Vaithiyanathan S. Diagnosis of Surface Defects in Hot-Rolled Steel from Deep Learning Features Using Machine Learning Algorithms. Arabian Journal for Science and Engineering. 2024:1-21.
109. Basit A, Manzoor HU, Akram M, Gelani HE, Hussain S. Machine learning-assisted anomaly detection for power line components: A case study in Pakistan. The Journal of Engineering. 2024;2024(7):e12405.
110. Gupta M, Meghana P, Reddy KH, Supraja P, editors. Predicting brain stroke using IoT-enabled deep learning and machine learning: Advancing sustainable healthcare. International Conference on Sustainable Development through Machine Learning, AI and IoT; 2023: Springer.
111. Toğaçar, M., Ergen, B., Cömert, Z., & Özyurt, F. (2020). A deep feature learning model for pneumonia detection applying a combination of mRMR feature selection and machine learning models. Irbm, 41(4), 212-222.
112. Jo, I., Lee, S., & Oh, S. (2019). Improved measures of redundancy and relevance for mRMR feature selection. Computers, 8(2), 42.
113. Cai, Y., Huang, T., Hu, L., Shi, X., Xie, L., & Li, Y. (2012). Prediction of lysine ubiquitination with mRMR feature selection and analysis. Amino acids, 42, 1387-1395.
114. Wang, G., Lauri, F., & El Hassani, A. H. (2022). Feature selection by mRMR method for heart disease diagnosis. IEEE Access, 10, 100786-100796.
115. Hermo, J., Bolón-Canedo, V., & Ladra, S. (2024). Fed-mRMR: A lossless federated feature selection method. Information Sciences, 669, 120609.
116. VE, S., & Cho, Y. (2023). Mrmr-eho-based feature selection algorithm for regression modelling. Tehnički vjesnik, 30(2), 574-583.
117. Niu, S., Huang, T., Feng, K., Cai, Y., & Li, Y. (2010). Prediction of tyrosine sulfation with mRMR feature selection and analysis. Journal of proteome research, 9(12), 6490-6497.
118. Özyurt, F. (2020). A fused CNN model for WBC detection with MRMR feature selection and extreme learning machine. Soft Computing, 24(11), 8163-8172.
119. Yan, X., & Jia, M. (2019). Intelligent fault diagnosis of rotating machinery using improved multiscale dispersion entropy and mRMR feature selection. Knowledge-Based Systems, 163, 450-471.
120. Jin, X., Ma, E. W., Cheng, L. L., & Pecht, M. (2012). Health monitoring of cooling fans based on Mahalanobis distance with mRMR feature selection. IEEE Transactions on Instrumentation and Measurement, 61(8), 2222-2229.
121. Rachburee, N., & Punlumjeak, W. (2015, October). A comparison of feature selection approach between greedy, IG-ratio, Chi-square, and mRMR in educational mining. In 2015 7th international conference on information technology and electrical engineering (ICITEE) (pp. 420-424). IEEE.
122. Idris, A., Khan, A., & Lee, Y. S. (2013). Intelligent churn prediction in telecom: employing mRMR feature selection and RotBoost based ensemble classification. Applied intelligence, 39, 659-672.
123. Hu, Q., Si, X. S., Qin, A. S., Lv, Y. R., & Zhang, Q. H. (2020). Machinery fault diagnosis scheme using redefined dimensionless indicators and mRMR feature selection. IEEE Access, 8, 40313-40326.
124. Li, Y., Yang, Y., Li, G., Xu, M., & Huang, W. (2017). A fault diagnosis scheme for planetary gearboxes using modified multi-scale symbolic dynamic entropy and mRMR feature selection. Mechanical Systems and Signal Processing, 91, 295-312.
125. Bansal, S. R., Wadhawan, S., & Goel, R. (2022). mRMR-PSO: a hybrid feature selection technique with a multiobjective approach for sign language recognition. Arabian Journal for Science and Engineering, 47(8), 10365-10380.
126. Wu, H., Yang, T., Li, H., & Zhou, Z. (2023). Air quality prediction model based on mRMR–RF feature selection and ISSA–LSTM. Scientific Reports, 13(1), 12825.
127. Ren, Z., Ren, G., & Wu, D. (2022). Deep learning based feature selection algorithm for small targets based on mRMR. Micromachines, 13(10), 1765.
128. Jiang, Y., & Li, C. (2015). mRMR-based feature selection for classification of cotton foreign matter using hyperspectral imaging. Computers and electronics in agriculture, 119, 191-200.
129. Peker, M., Şen, B., & Delen, D. (2015). Computer-Aided Diagnosis of Parkinson's Disease Using Complex-Valued Neural Networks and mRMR Feature Selection Algorithm. Journal of healthcare engineering, *6*(3), 281-302.