

Akciğer ve Meme Kanserinde Yapay Zekâ: LLM ve LVM ile Öneriler

Berra ÖZ^{1*}, Ali Hakan IŞIK²

^{1,2} Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 15000, Burdur

¹<https://orcid.org/0009-0000-9236-4394>

²<https://orcid.org/0000-0003-3561-9375>

*Sorumlu yazar: berraaz@mehmetakif.edu.tr

Derleme

Makale Tarihiçesi:

Geliş tarihi: 24.12.2024

Kabul tarihi: 11.05.2025

Online Yayınlanma: 15.12.2025

Anahtar Kelimeler:

Derin öğrenme

Makine öğrenmesi

Large language model

Large vision model

ÖZ

Kanser, vücut hücrelerinin kontrolsüz bir şekilde büyüyüp çoğalması sonucunda oluşan bir hastalıktır. Akciğer ve meme kanseri, dünya genelinde en sık görülen kanser türlerinden biridir ve bu nedenle kanser teşhisi, hastalığın erken evrelerinde tespit edilmesi ve tedaviye başlanması açısından kritik bir öneme sahiptir. Geleneksel teşhis yöntemleri zaman zaman yeterince hassas sonuçlar vermemektedir. Bu bağlamda, yapay zekâ destekli kanser teşhisi önemli bir rol oynamaktadır. Yapay zekâ daha geniş bir veri yelpazesini ele alarak kanser teşhisinde fark edilemeyecek önemli ayrıntıları algılayabilmekte ve belirli kanser türlerini erken aşamada tespit edebilmektedir. Bu derleme makalesi, 2020 ile 2023 yılları arasında yapılan çalışmalarda, akciğer ve meme kanseri tanısında kullanılan makine öğrenimi ve derin öğrenme algoritmalarının detaylı bir incelemesini sunmayı ve bu algoritmaların akciğer ve meme kanseri teşhisi performanslarını değerlendirmeyi amaçlamaktadır. Bu çalışmada 30 makale incelenmiş, ele alınan makalelerdeki makine öğrenmesi ve derin öğrenme algoritmalarının zaman karmaşıklıkları analiz edilmiştir. Bu doğrultuda LLM (Large Language Model) ve LVM (Large Vision Model)'nin onkoloji alanındaki etkinliği değerlendirilmiştir. Bu modellerin potansiyelini artırmak ve onkoloji alanındaki uygulamalarda etkin bir şekilde kullanımının genişletilebilmesi amacıyla çeşitli önerilerde bulunulmuştur. Bu çalışmanın, klinik uygulamalarda algoritmaların performansını değerlendirmek için önemli bir rehber olabileceği ve LLM ile LVM'lerin tıbbi uygulamalardaki potansiyelini vurgulayarak bu alandaki ilerlemelerin önemini ve etkisini geniş bir kitleye duyurabileceği düşünülmektedir.

Artificial Intelligence in Lung and Breast Cancer: Recommendations with LLM and LVM

Reviews

Article History:

Received: 24.12.2024

Accepted: 11.05.2025

Published online: 15.12.2025

Keywords:

Deep learning

Machine learning

Large language model

Large vision model

ABSTRACT

Cancer is a disease caused by the uncontrolled growth and proliferation of body cells. Lung and breast cancers are among the most common types of cancer worldwide. Therefore, early detection of cancer and timely initiation of treatment are critically important. Traditional diagnostic methods may sometimes struggle to provide accurate results. In this context, artificial intelligence (AI)-assisted cancer diagnosis plays a pivotal role. AI can analyze a broader range of data and detect critical details that might otherwise go unnoticed, enabling the early detection of specific types of cancer. This review article aims to provide a detailed examination of machine learning (ML) and deep learning (DL) algorithms used in the diagnosis of lung and breast cancer in studies conducted between 2020 and 2023. In this study, 30 articles were analyzed and the time complexity of machine learning and deep learning algorithms were analyzed. Accordingly, the effectiveness

of LLM (Large Language Model) and LVM (Large Vision Model) in the field of oncology was evaluated. To further enhance the potential of these models and expand their effective use in oncology applications, various recommendations are proposed. It is thought that the study can be an important guide for evaluating the performance of algorithms in clinical applications and can convey the importance and impact of advances in this field to a wider audience by emphasizing the potential of LLMs and LVMs in medical applications.

To Cite: Öz B., Işık AH. Akciğer ve Meme Kanserinde Yapay Zekâ: LLM ve LVM ile Öneriler. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 2025; 8(5): 2574-2593.

1. Giriş

Kanser, vücut hücrelerinin kontrolsüz bir şekilde büyüüp çoğalması sonucunda oluşan bir hastalıktır. Normal koşullarda, vücut hücreleri belirli bir düzen ve kontrol mekanizması altında çoğalır, büyür ve ölür. Ancak kanserde, bu kontrol mekanizmaları bozulur ve hücreler normal sınırlarını aşarak vücutta istilacı bir şekilde büyümeye devam eder.

Uluslararası Kanser Araştırma Ajansı'na göre dünya çapında her beş kişiden biri yaşamı boyunca kansere yakalanmaktadır. Mevcut bilimsel kanıtlar, kanserde erken teşhisin önemli bir etkisi olduğunu göstermektedir (International Agency for Research on Cancer [IARC]). Akciğer ve meme kanseri gibi sık rastlanan kanser türlerinde erken teşhisin, hastalığın seyrini olumlu yönde etkilediği bilinmektedir. Etkili birincil önleme tedbirleriyle tüm kanser vakalarının en az %40'ının önlenmesi mümkündür. Erken teşhis ile tedavi seçenekleri artmakta, tedaviye daha iyi yanıt alınmakta ve uzun vadeli sağkalım oranları büyük ölçüde yükselmektedir. Bunun yanında erken aşamada tespit edilen kanserlere, daha az agresif tedavi yöntemleri uygulanabilmekte ve bu da hastaların yaşam kalitesini büyük oranda artırmaktadır. Geleneksel teşhis yöntemleri arasında biyopsi, çeşitli görüntüleme teknikleri, kan testleri ve fiziksel muayene bulunmaktadır. Ancak bu yöntemler bazen yeterince doğru sonuçlar vermemekte ve yanıltıcı olabilmektedir. Bu bağlamda yapay zekâ ile kanser teşhisi büyük önem taşımaktadır.

Makine öğrenimi, bilgisayar sistemlerinin belirli veri setleri üzerinden öğrenme yapabildiğini ve bu verilerden bilgi çıkarabildiğini sağlayan yapay zekâ alanının bir dalı olarak tanımlanmaktadır. Gelişen teknoloji ve veri işleme yetenekleri ile, makine öğrenimi sağlık alanında hastalık teşhislerinde daha hassas ve erken sonuçlar elde etmeye, tedavi süreçlerini kişiselleştirmeye ve sağlık hizmetlerini optimize etmeye olanak tanımaktadır. Bu teknoloji, geniş veri setlerini analiz ederek kanser teşhisinde fark edilemeyecek ince ayrıntıları algılayabilmekte ve belirli kanser türlerini erken aşamada tespit edebilme yeteneği sunmaktadır (Veranyurt ve ark., 2020).

Derin öğrenme, büyük miktarda veri üzerinden öğrenme yeteneği olan yapay sinir ağlarının kullanıldığı, makine öğreniminin bir alt dalıdır. Derin öğrenme modelleri, büyük miktarda veriden öğrenebilmekte ve bu da onları karmaşık görevleri gerçekleştirmek için eğitmeyi mümkün kılmaktadır. Derin öğrenme, karmaşık medikal veri setlerini işleyebilme yeteneği sayesinde kanser teşhisinde önemli bir potansiyele sahiptir. Özellikle tıbbi görüntülerden kanser teşhisinde etkili ve hassas bir araç olarak kullanılabilir (Cifci, 2022).

Bu derleme makalesi, akciğer ve meme kanseri teşhisi için makine öğrenimi ve derin öğrenme algoritmalarının 2020 ile 2023 yılları arasında yapılan çalışmalarda kullanımının detaylı bir incelemesini sunmayı amaçlamaktadır. Yapılan çalışmaya 30 makale dahil edilmiştir. Derleme, akciğer ve meme kanseri teşhisi için kullanılan derin öğrenme ve makine öğrenimi temelli algoritmaların performanslarını değerlendirmeyi amaçlamaktadır. Bu bağlamda, incelenen çalışmalar kanser türü, kullanılan algoritmalar, veri seti, veri türü ve son olarak ayrı bir tabloda performans metrikleri başlıklarını içerecek şekilde sıralanmaktadır. Oluşturulan bu yapı, incelenen çalışmaların detaylı ve düzenli bir şekilde sunulmasını sağlamaktadır. Bununla birlikte makine öğrenmesi ile derin öğrenme algoritmalarının zaman karmaşıklıkları analiz edilmiş ve farklı veri türlerine bağlı olarak en yüksek performans gösteren beş algoritma belirlenerek tablo halinde sunulmuştur.

Yapılan analizlerin ardından, LLM (Large Language Model) ve LVM (Large Vision Model)'nin onkoloji alanındaki etkinliği incelenmiş, bu modellerin potansiyelini artırmak ve onkoloji alanındaki uygulamalarda etkin bir şekilde kullanımının genişletilebilmesi amacıyla çeşitli önerilerde bulunulmuştur. Yapılan derlemede çalışmaların sentezlenmesinin, farklı algoritmaların akciğer ve meme kanseri teşhisi üzerindeki etkinliğinin ve başarısının karşılaştırılabilmesine olanak tanıdığı klinik uygulamalarda algoritmaların performanslarını değerlendirmeye yönelik önemli bir yol gösterici olabileceği, aynı zamanda LLM ve LVM'lerin tıbbi uygulamalardaki potansiyelini vurgulayarak, bu alandaki ilerlemelerin önemini ve etkisini daha geniş bir kitleye ulaştırabileceği düşünülmektedir.

2. Materyal ve Metot

2.1. Araştırma Soruları

Bu çalışma,

“Akciğer ve Meme kanserinde kullanılan makine öğrenimi ve derin öğrenme algoritmaları hangileridir?”

“Makine öğrenmesi ve derin öğrenme algoritmaları akciğer ve meme kanseri teşhisi için ne kadar etkili ve doğru sonuçlar vermektedir?”

“LLM (Large Language Model) ve LVM (Large Vision Model) onkoloji alanında nasıl kullanılabilir ve kanser araştırmalarına ne tür katkılarda bulunabilir?”

Sorularına cevap vermeyi amaçlamaktadır.

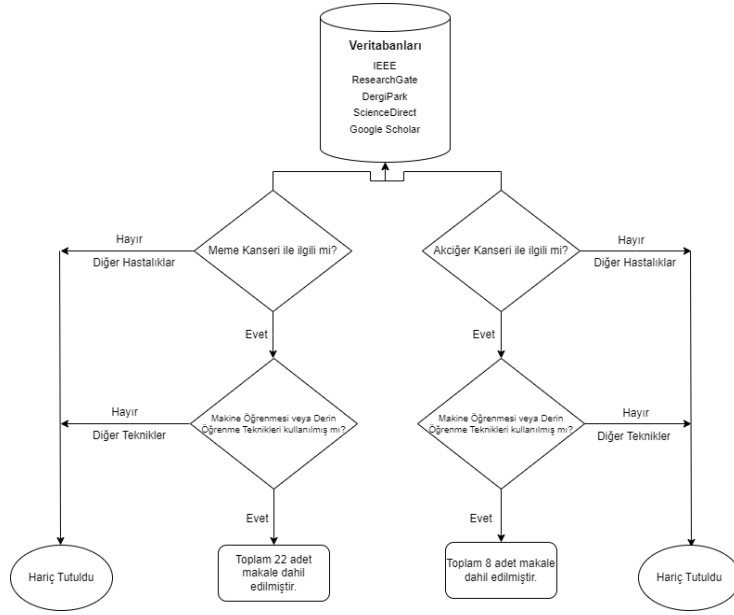
2.2. Veri Toplama

Araştırma kapsamına, 2020-2023 yılları arasında yayımlanan ve kanser teşhisine odaklanan 30 makale dahil edilmiş olup, bu makaleler Google Scholar ve IEEE Xplore veri tabanlarından seçilmiştir. İncelenen makaleler, makine öğrenimi ve derin öğrenme algoritmalarının kullanımı ile kanser teşhisindeki gelişmeleri ele almaktadır.

Belirtilen veri tabanlarından konuyla ilgili makaleler toplanmıştır. Bu işlemin ardından toplanan makaleler taranarak çalışmaya dahil edilmesi planlanan makaleler tam metin incelemesine tabi

tutulmuştur. Her makalenin incelenmesinin ardından kanser türü, araştırmada kullanılan algoritmalar, veri seti, veri türü ve en yüksek performansa sahip algoritma listelenmiştir. Performans değerlendirmesinde doğruluk (accuracy), kesinlik (precision), duyarlılık (sensitivity), özgünlük (specificity), F-puanı ve AUC (ROC eğrisinin altındaki alan) metrikleri baz alınmıştır.

Araştırmada incelenen makalelerde toplam 33 farklı algoritma kullanıldığı tespit edilmiştir. Yoğun olarak kullanılan makine öğrenmesi ve derin öğrenme algoritmaları bir sonraki başlık altında incelenmektedir.



Şekil 1. Literatür taramasında kullanılan yöntemin görsel özeti

Şekil 1, veri tabanı taramasının hangi kriterlere göre gerçekleştirildiğini göstermektedir. İlk olarak, meme kanseri ve akciğer kanseri hakkında bir araştırma yapılacağı için ilgili hastalıklara odaklanan çalışmalar seçilmiştir. Daha sonra, seçilen makalelerde makine öğrenmesi veya derin öğrenme gibi yapay zekâ tekniklerinin kullanılıp kullanılmadığı sorgulanmıştır. Bu kriterlere sahip 22'si meme kanseri ve 8'i akciğer kanseri olmak üzere toplam 30 makale analiz edilmiştir.

2.3. Makine Öğrenmesi Algoritmaları

2.3.1. Lojistik Regresyon

Verileri sınıflandırmak amacıyla kullanılan lojistik regresyon, istatistik ve makine öğrenimi alanlarında basitliği ve yorumlanabilirliği ile öne çıkan bir algoritmadır. Özellikle ikili sınıflandırma problemlerinde kullanılır. Algoritma, veri noktalarının belirli bir kategoriye ait olma olasılığını tahmin etmek için kullanılır. Lojistik regresyon algoritması, ağırlıklar ve özellikler arasındaki ilişkiyi ifade eden bir model oluşturur. Bu model, girdi özelliklerinin ağırlıklı toplamını alır ve ardından bir aktivasyon fonksiyonu olarak "sigmoid" adı verilen bir fonksiyondan geçirir. Sigmoid fonksiyonu, sonucu bir olasılık değeri olarak temsil etmek üzere 0 ile 1 arasında dönüştürür.

2.3.2. Destek Vektör Makinesi

Makine öğrenimi alanında sıklıkla kullanılan Destek Vektör Makinesi, sınıflandırma ve regresyon problemlerinde etkin bir performans sergiler. Veri noktaları arasında en iyi ayrımı sağlayacak bir karar sınırı oluşturarak farklı sınıfları belirler. Bu sınıflandırma sürecinde, destek vektörleri kullanarak sınıflar arası marjı maksimize etmeyi hedefler. Lineer veya non-lineer veri setlerinde etkili olarak kullanılabilir.

2.3.3. K-En Yakın Komşu Algoritması

Sınıflandırma ve regresyon problemlerinde K-En Yakın Komşu algoritması, yaygın bir şekilde kullanılan bir makine öğrenimi yaklaşımıdır. Bu algoritma, yeni bir veri noktasının sınıflandırma veya tahminini yaparken, ona en yakın olan "k" adet komşusunun bilgisine dayanır. Sınıflandırma için, komşuların etiketleri kullanılarak çoğunluk oyu yöntemiyle sınıf belirlenir. Regresyon problemlerinde ise komşuların değerleri, ortalaması veya ağırlıklı ortalaması gibi yöntemler kullanılarak yeni veri noktasının tahmini değeri hesaplanır.

2.3.4. Naive Bayes

Naive Bayes, sınıflandırma problemlerinde yaygın olarak tercih edilen bir makine öğrenimi algoritmasıdır. Bu algoritma, veri noktalarını belirli sınıflara atamak için olasılık tabanlı bir yaklaşım kullanır. Temelde Bayes teoremi esasına dayanır ve özellikler arasındaki bağımsızlık varsayımını temel alır. Eğitim aşamasında, veri setindeki özelliklerin ve sınıfların olasılıklarını hesaplar. Ardından, yeni bir veri noktasını sınıflandırmak için bu olasılıkları kullanır.

2.3.5. Rastgele Orman

Rastgele Orman, makine öğrenimi alanında sınıflandırma ve regresyon problemlerine yönelik bir topluluk öğrenme metodudur. Temel amacı, birçok karar ağacının bir araya getirilmesiyle daha güçlü ve kararlı bir model oluşturmaktır. Rastgele Orman, farklı özelliklere dayalı çok sayıda karar ağacı oluşturur. Her karar ağacı rastgele seçilen özelliklerle ve farklı veri alt kümeleri üzerinde eğitilir. Bu durum her bir ağacın diğerlerinden farklı olmasını sağlar. Yeni bir veri noktasının tahmini yapılırken, her ağaçtan gelen sonuçların ortalaması (sınıflandırma için) veya toplamı (regresyon için) alınarak bir tahmin oluşturulur.

2.4. Derin Öğrenme Algoritmaları

2.4.1. ResNet

Derin öğrenme alanında kullanılan ResNet adı verilen sinir ağı mimarisi, ağın daha derin olmasının getirdiği olumsuz etkileri azaltmak için geliştirilmiştir. Geleneksel olarak, ağların derinleşmesi eğitim sırasında performans kaybına veya aşırı öğrenme sorunlarına yol açabilmektedir. Bu durumlar, derin ağların eğitimini zorlaştırabilmektedir. ResNet, bu tür sorunları aşmak için "kalıntı öğrenme" adı

verilen bir teknik kullanır. Bu teknik, ađın katmanları arasında dođrudan bađlantılar ekleyerek, atlamalı bađlantılar adı verilen özel bir yapı oluşturur. Bu yapı, daha derin ađların eđitiminde oluřabilecek gradient kaybını azaltır ve ađın daha verimli öğrenmesini sađlar. Bu sayede, ResNet mimarisi daha derin ve etkili sinir ađı modellerinin geliřtirilmesinde önemli bir adımı temsil eder.

ResNet ailesinin versiyonları, katman sayılarına ve karmařıklıklarına göre farklılařır. ResNet-18 ve ResNet-34, sırasıyla 18 ve 34 katmandan oluřur; daha hafif ve daha küçük boyutludur, ancak yine de etkili sonuçlar verir. ResNet-50, ResNet-101, ResNet-152 ve ResNet-110 ise daha büyük derinliklere sahiptir; bu modeller daha karmařık öğrenme problemleri için uygundur. ResNet-164 ve ResNet-1202 ise daha da derin yapıdadır. Her bir model, özel blok yapıları ve atlamalı bađlantılar gibi tekniklerle ađın derinleřmesine olanak tanıyan farklı özellikler sunar.

ResNetV2, ResNet'in geliřtirilmiř bir versiyonudur; önceki sürümlerdeki yapısal sorunları düzeltir, daha iyi eđitim stabilitesi sađlar ve daha düşük hesaplama maliyeti sunar. Wide ResNet, daha geniř bir yapıya sahiptir ve her katmandaki kanal sayısını artırarak daha fazla öğrenme kapasitesi sađlar. ResNeXt, paralel iřleme gücünü artırmak için birden çok paralel yol kullanır ve daha fazla esneklik sunar. Pre-activated ResNet (PreResNet), normalleřtirme ve aktivasyon katmanlarının konvolüsyon katmanlarından önce yer aldıđı bir yapıya sahiptir; bu yapı, daha stabil eđitim davranıřı sergileyebilmektedir.

2.4.2. *EfficientNet*

EfficientNet, Google Brain tarafından geliřtirilen ve ölçeklenebilirlik, performans ve verimlilik açısından optimize edilmiř bir evriřimli sinir ađı (CNN) mimarisidir. EfficientNet, özellikle görüntü sınıflandırma ve bilgisayarlı görü üzerine çalıřan bir derin öğrenme modelidir. Bu mimari, 'bileřik ölçeklendirme' adı verilen bir strateji kullanarak ađın derinliđini, geniřliđini ve derinlik/çözünürlük boyutlarını aynı anda ölçeklendirir. Yani, daha derin, daha geniř ve daha yüksek çözünürlüklü modeller oluřtururken hesaplama maliyetini minimize eder. Bu sayede, daha az parametre kullanarak daha iyi performans elde etmeyi amaçlar.

EfficientNet, çeřitli varyasyonlardan oluřan ölçeklenebilir bir evriřimli sinir ađı mimarisidir. EfficientNet'in temel varyasyonları B0'dan B7'ye kadar sıralanır. B0, en hafif ve en küçük boyutlu modelken, B7 en büyük ve karmařık olanıdır. EfficientNet-EdgeTPU, yerel cihazlarda hızlı ve verimli çalıřma sađlayan bir versiyon olarak öne çıkar. Mobil cihazlar için tasarlanan EfficientNet-Lite varyasyonları daha küçük boyutta ve düşük hesaplama maliyetiyle çalıřırken, EfficientNetV2 ilk versiyonun geliřtirilmiř bir řeklidir ve daha iyi eđitim stabilitesi ile daha düşük hesaplama maliyeti sunar.

2.4.3. *VGG*

Visual Geometry Group (VGG), Oxford Üniversitesi'nde bulunan bir arařtırma grubunun geliřtirdiđi derin evriřimli sinir ađı (CNN) mimarisidir. VGG'nin temel özelliđi, öğrenme ve anlama sürecindeki

derinliđi artırmak için birbirini takip eden çok sayıda konvolüsyonel katmanın kullanılmasıdır. Bu mimari, basit ve tekrarlanabilir bir yapıya sahiptir. Özellikle 3x3 boyutundaki küçük filtrelerin yoğun bir şekilde kullanılması VGG'nin önemli bir özelliđidir.

VGG'nin farklı varyasyonları, VGG-16 ve VGG-19 gibi "VGG" adının ardından katman sayısını belirten bir numara ile adlandırılır. VGG-16, toplamda 16 katmandan oluşurken, bunların çoğunluđunu evrişim katmanları oluşturur ve ardından tam bağlantılı katmanlar gelir. VGG-19 ise 19 katmandan oluşur ve VGG-16'dan farklı olarak daha fazla evrişim ve tam bağlantılı katmana sahiptir. VGG'nin tekrarlanan ve sıralı katman yapısı, anlam çıkarma yeteneđini artırırken daha derin bir ađ yapısı sağlar.

2.4.4. Inception

Inception, Google tarafından geliştirilen ve derin öğrenme alanında etkili olan bir sinir ađı mimarisidir. Inception mimarisi, paralel evrişim katmanlarının farklı boyutlarda filtrelerle çalıştığı ve bu katmanların çıktılarının birleştirilerek kullanıldığı bir yapıya sahiptir. Bu yaklaşım, ađı daha etkili hale getirirken hesaplama maliyetini azaltmaya yöneliktir.

Inception mimarisi, çeşitli versiyonlara ayrılmıştır. İlk versiyon olan Inception v1, karmaşık yapıları basit evrişim katmanları ve paralel bağlantılarla ele alarak dikkat çeker. Bu versiyon, daha derin ađlara kıyasla daha hafif ve etkili olarak bilinir. Ardışık versiyonlar olan Inception v2 ve v3, özellikle daha küçük filtreler ve daha derin evrişim katmanlarıyla orijinal mimariyi geliştirir ve iyileştirmeler getirir. Inception v4 ise daha da derinleştirilmiş ve optimize edilmiş bir yapı sunar, özellikle karmaşık bağlantılar, daha fazla evrişim katmanı ve etkili ölçeklenebilirlik gibi özellikleri vurgular.

2.4.5. CNN

Evrişimli Sinir Ađı (CNN veya Convolutional Neural Network), görüntü tanıma, nesne algılama ve diđer görsel analiz görevlerinde kullanılan bir yapay sinir ađı mimarisidir. CNN, görüntüyü farklı katmanlarda işleyerek analiz etmektedir. Bu katmanlar Evrişim Katmanı, Havuzlama Katmanı ve Tam Bağlantılı Katman olarak sıralanmaktadır. Evrişim katmanı, girdi verisinde farklı özellikleri tespit etmek ve bu özellikleri öğrenmek için kullanılır. Bu katman, filtre matrislerini kullanarak girdi verisi üzerinde gezinir ve özellik haritaları veya özellik çıktıları oluşturur. Evrişim işlemi, verinin lokal özelliklerini belirlemeye yardımcı olur.

Havuzlama katmanı, evrişim katmanının çıkışlarını alır ve boyutlarını küçültmek, hesaplama yükünü azaltmak ve özellikleri daha genelleştirmek için kullanılır. Tam bağlantılı katmanı, özellik haritalarını düzleştirerek bir vektör haline getirir ve geleneksel yapay sinir ađları gibi çalışır. Bu katman, düzleştirilmiş girişi alır ve sınıflandırma, regresyon veya diđer çıktıları üretmek için kullanılır. Ađın sonuçlarını üreterek istenen çıktıları elde etmemizi sağlar.

3. Bulgular ve Tartışma

Tablo 1’de akciğer kanseri ve Tablo 2’de meme kanseri için her bir çalışma kapsamında kanser türü, kullanılan algoritmalar, veri seti ve veri türü derlenip tablolaştırılmıştır. İncelenen çalışmalardaki modellerin başarımı, doğruluk (accuracy), kesinlik (precision), duyarlılık (sensitivity), özgüllük (specificity), F-puanı ve AUC (ROC eğrisinin altındaki alan) metrikleri ile Tablo 3’te belirtilmiştir.

Tablo 1. Akciğer kanseri kapsamında incelenen çalışmaların özeti

Referans	Kanser Türü	Algoritmalar	Veri Seti	Veri Türü
(Dirik, 2023)	Akciğer Kanseri	Naive Bayes Lojistik Regresyon Karar Ağacı Rastgele Orman Gradient Boosting Destek Vektör Makinesi	309 kişinin yanıtlarından oluşan akciğer kanseri anketi	Yapılandırılmış Anket Verisi
(Alomar ve ark., 2023)	Akciğer Kanseri	ResNet-50 InceptionV3	Kaggle üzerinden elde edilen Akciğer BT görüntüleri	Görüntü Verisi
(Subramanian ve ark., 2020)	Akciğer Kanseri	AlexNet + SVM AlexNet + Deep kNN AlexNet Model + softmax	100 görüntü (50 kanseri, 50 normal) veri artırımı teknikleri kullanılarak genişletilmiştir.	Görüntü Verisi
(Bouamrane ve Derdour, 2023)	Akciğer Kanseri	K-En Yakın Komşu Destek Vektör Makinesi Wide-Resnet-50-2- weight Karar Ağacı Rastgele Orman VGG-19 EfficientNetV2-L EfficientNet-B7	LIDC-IDRI veri seti	Görüntü Verisi
(Aziz ve ark., 2023)	Akciğer Kanseri	Yapay Sinir Ağları Destek Vektör Makinesi K-En Yakın Komşu Naive Bayes	LIDC-IDRI veri seti	Görüntü Verisi
(Lathakumari ve ark., 2023)	Akciğer Kanseri	EfficientNetB2	1000 akciğer BT görüntüsü (Eğitim 613 görüntü, Test 72 görüntü, Doğrulama 315 görüntü)	Görüntü Verisi
(Mohalder ve ark., 2021)	Akciğer Kanseri	CatBoost Karar Ağacı Lojistik Regresyon Doğrusal Diskriminant	LC25000 veri seti	Görüntü Verisi

Analizi				
(Peng ve Wu, 2023)	Akciğer Kanseri	AlexNet	LC25000 dataset	Görüntü Verisi

Tablo 2. Meme kanseri kapsamında incelenen çalışmaların özeti

Referans	Kanser Türü	Algoritmalar	Veri Seti	Veri Türü
(Allugunti, 2022)	Meme Kanseri	CNN Destek Vektör Makinesi Rastgele Orman	150'den fazla hastaya ait, meme kanseri olan veya olmayan toplamda 1000'den fazla görüntü	Görüntü Verisi
(Iqbal ve ark., 2020)	Meme Kanseri	K-En Yakın Komşu Çok Katmanlı Algılayıcı Destek Vektör Makinesi Rastgele Orman	Wisconsin Breast Cancer veri seti	Yapılandırılmış Veri (Numerik)
(Kadhim ve Kamil, 2023)	Meme Kanseri	Doğrusal Diskriminant Analizi Karar Ağacı Rastgele Orman Gradient Boosting Passive Aggressive Lojistik Regresyon Naive Bayes Nearest Centroid Destek Vektör Makinesi Perceptron	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Lee ve Sun, 2022)	Meme Kanseri	K-En Yakın Komşu Yapay Sinir Ağları Lojistik Regresyon	Wisconsin Breast Cancer veri seti	Yapılandırılmış Veri (Numerik)
(Naji ve ark., 2021)	Meme Kanseri	Destek Vektör Makinesi Rastgele Orman Lojistik Regresyon Karar Ağacı K-En Yakın Komşu	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Zhou, 2022)	Meme Kanseri	Lojistik Regresyon	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Akbar ve ark., 2023)	Meme Kanseri	CNN DenseNet121 EfficientNetV2	BreakHis veri seti	Görüntü Verisi
(Altan, 2020)	Meme Kanseri	CNN	DDSM veri seti	Görüntü Verisi
(Das ve ark., 2023)	Meme Kanseri	Destek Vektör Makinesi Rastgele Orman Karar Ağacı Lojistik Regresyon	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Ak, 2020)	Meme Kanseri	Lojistik Regresyon K-en yakın komşu Destek Vektör	Wisconsin Breast Cancer veri seti	Yapılandırılmış Veri (Numerik)

		Makinesi Naive Bayes Karar Ağacı Rastgele Orman Rotation Forest		
(Benhassine ve ark., 2020)	Meme Kanseri	Destek Vektör Makinesi Yapay Sinir Ağları Rastgele Orman Naive Bayes	Mammographic Image Analysis Society	Görüntü Verisi
(Mahmud ve ark., 2023)	Meme Kanseri	ResNet-50 ResNet-101 VGG-16 VGG-19	2453 Histopatoloji Görüntüsü (Kaggle)	Görüntü Verisi
(Salama ve Aly, 2021)	Meme Kanseri	InceptionV3 DenseNet-121 ResNet-50 VGG-16 MobileNetV2	DDSM veri seti	Görüntü Verisi
(Manjunathan ve ark., 2023)	Meme Kanseri	Rastgele Orman Karar Ağacı Lojistik Regresyon	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Mishra ve Agarwal, 2022)	Meme Kanseri	Destek Vektör Makinesi Naive Bayes Lojistik Regresyon K-En Yakın Komşu	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Mahoro ve Akhloufi, 2024)	Meme Kanseri	EfficientNet-B7 ResNet-50 VGG-16 DenseNet-201	DMR-IR veri seti	Görüntü Verisi
(Akash, 2024)	Meme Kanseri	Lojistik Regresyon K-en yakın komşu Rastgele Orman Karar Ağacı XGBoost	Meme biyopsi örnekleri	Yapılandırılmış Veri (Numerik)
(Promtan ve ark., 2023)	Meme Kanseri	Karar Ağacı K-En Yakın Komşu Lojistik Regresyon Naive Bayes	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Telsang ve Hegde, 2020)	Meme Kanseri	Naive Bayes Rastgele Orman Lojistik Regresyon Destek Vektör Makinesi K-En Yakın Komşu	Wisconsin Breast Cancer veri seti	Yapılandırılmış Veri (Numerik)
(Thabit, 2023)	Meme Kanseri	Naive Bayes K-En Yakın Komşu Rastgele Orman Karar Ağacı Lojistik Regresyon Destek Vektör Makinesi	Wisconsin Breast Cancer veri seti (Diagnostic)	Yapılandırılmış Veri (Numerik)
(Mangukiya ve ark., 2022)	Meme Kanseri	Destek Vektör Makinesi Karar Ağacı Naive Bayes K En Yakın Komşu Adaboost XGboost	Wisconsin Breast Cancer veri seti	Yapılandırılmış Veri (Numerik)

		Rastgele Orman			
(Sayın ve ark., 2023)	Meme Kanseri	VGG	ResNet	BreakHis veri seti	Görüntü Verisi
		Xception	Inception		
		InceptionResNet			

Tablo 3. İncelenen çalışmaların performans göstergeleri

Referans	Algoritma	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F-puanı	AUC
	Naive Bayes	%91	%92	%97	-	-	%67,2
(Dirik, 2023)	Destek Vektör Makinesi	%91	%96	%94	-	-	%44,4
(Alomar ve ark., 2023)	ResNet50	%100	-	-	-	-	-
(Subramanian ve ark., 2020)	AlexNet Model + softmax	%99,52	%99,20	%88,26	-	%93,41	-
(Bouamrane ve Derdour, 2023)	VGG-19	%99,71	%99,96	-	%99,96	-	%99,97
(Aziz ve ark., 2023)	K-En Yakın Komşu	%98,5	-	-	-	-	-
(Lathakumari ve ark., 2023)	EfficientNetB2	%83	-	-	-	-	-
(Mohalder ve ark., 2021)	CatBoost	%99,8	%100	%100	-	%100	-
(Peng ve Wu, 2023)	AlexNet	%99,46	-	-	-	-	-
(Allugunti, 2022)	CNN	%99,67	-	-	-	-	-
(Iqbal ve ark., 2020)	Rastgele Orman	%99,26	%98,99	%100	-	%99,44	-
(Kadhim ve Kamil, 2023)	Gradient Boosting	%97,36	%97,82	%95,74	%98,5	%96,77	-
(Lee ve Sun, 2022)	Yapay Sinir Ağları	%96	-	-	-	-	-
(Naji ve ark.,2021)	Destek Vektör Makinesi	%97,2	%98	%94	-	%96	%96,6
(Zhou, 2022)	Lojistik Regresyon	Model_1: %96,5 Model_2: %93,6	-	-	-	-	-
(Akbar ve ark., 2023)	EfficientNetV2	%98	-	-	-	-	-
(Altan, 2020)	CNN	%92,84	-	%95,30	%96,72	-	-

(Das ve ark., 2023)	Destek Vektör Makinesi	%97,37	%97,62	%95,35	-	-	-
(Ak, 2020)	Lojistik Regresyon	%98,1	-	-	-	-	-
(Benhassine ve ark., 2020)	Destek Vektör Makinesi	%99,41	-	-	-	-	-
(Mahmud ve ark., 2023)	ResNet50	%90,2	-	%94,7	-	-	%90
(Salama ve Aly, 2021)	U-Net + Inception-V3	%98,87	%98,79	%98,98	-	%97,99	%98,88
(Manjunathan ve ark., 2023)	Rastgele Orman	%96,5	%97	%97	-	%97	-
(Mishra ve Agarwal, 2022)	Destek Vektör Makinesi	%98	%99	%97	%98	%98	-
(Mahoro ve Akhloufi, 2024)	ResNet-50	%97,26	-	%97,26	%96,94	-	-
(Akash, 2024)	Lojistik Regresyon	%98,25	-	-	-	-	-
(Promtan ve ark., 2023)	Naive Bayes	%93	%90	%91	-	%90	-
(Telsang ve Hegde, 2020)	Destek Vektör Makinesi	%96,25	%100	%88	-	%94	%99,4
(Thabit, 2023)	Destek Vektör Makinesi	%99,1	-	-	-	-	-
(Mangukiya ve ark., 2022)	XGboost	%98,24	-	-	-	-	-
(Sayın ve ark., 2023)	Xception	%89	%90	%90	-	%90	-

Tablo 1, akciğer kanseri teşhisinde; Tablo 2 ise meme kanseri teşhisinde çeşitli algoritmaların etkili kullanımını araştıran önemli çalışmaları içermektedir. Tablo 3'te belirtilen performans değerleri, yapay zekâ modellerinin kanser teşhisinde önemli bir rol oynadığını göstermektedir.

3.1. Makine Öğrenmesi Algoritmalarının Zaman Karmaşıklığı Analizi

Zaman karmaşıklığı, bir algoritmanın çalışması için gereken zamanın, girdi boyutuna bağlı olarak gösterdiği performansın bir ölçüsüdür. Big O notasyonu ise zaman karmaşıklığını analiz etmek amacıyla kullanılan matematiksel dili ifade etmektedir. Tablo 4, eğitim zaman karmaşıklığı temel alınarak oluşturulmuştur.

Tablo 4. Makine Öğrenmesi Algoritmaları Zaman Karmaşıklığı Tablosu

Algoritma	Zaman Karmaşıklığı
Destek Vektör Makinesi	$O(n^2 \times d)$ ile $O(n^3)$
Naive Bayes	$O(n \times d \times c)$
Lojistik Regresyon	$O(n \times d)$
Karar Ağacı	$O(n \times d \times \log n)$
K-En Yakın Komşu	$O(1)$
Gradient Boosting	$O(M \times n \times \log n \times d)$
Rastgele Orman	$O(M \times n \times \log n \times d)$
Perceptron	$O(n \times d \times k)$
Doğrusal Diskriminant Analizi	$O(n \times d \times t + t^3)$
Passive Aggressive	$O(n \times d \times k)$
Nearest Centroid	$O(n \times d)$
CatBoost	$O(M \times n \times \log n \times d)$
AdaBoost	$O(M \times n \times d)$
XGBoost	$O(M \times n \times \log n \times d)$
Döndürme Ormanı (Rotation Forest)	$O(M \times (n \times d^2 + d^3))$

n: eğitim örnek sayısı, d: özellik (feature) sayısı, k: iterasyon sayısı, c: Sınıf sayısı, M: ağaç sayısı (ensemble içindeki model sayısı), t: $\min(n,d)$ en küçük boyut (matris işlemleri için sınır)

3.2. Derin Öğrenme Algoritmalarının Zaman Karmaşıklığı Analizi

Derin öğrenme modellerinin zaman karmaşıklığını kesin bir formda belirtmek mümkün değildir. Bu modellerin çalışma süreleri birçok faktöre bağlı olarak değişmektedir. Modellerin çok katmanlı yapıya sahip olmaları, kullanılan donanımın özellikleri, girdi boyutu ve parametrelerin değişkenliği gibi birçok etken Big O gösteriminin kesin sonuç vermesini zorlaştırmaktadır. Dolayısıyla Tablo 5'te sunulan değerler sabit bir giriş boyutu ($224 \times 224 \times 3$) baz alınarak hesaplanan FLOPs (Floating Point Operations - Kayan Nokta İşlemleri) değerlerinden türetilmiş yaklaşık temsilleri ifade etmektedir. FLOPs bir modelin hesaplama karmaşıklığını ve işlem yükünü analiz etmekte kullanılır özetle modelin teorik işlem miktarını belirtmektedir.

Tablo 5. Derin Öğrenme Modelleri Yaklaşık Zaman Karmaşıklığı Tablosu

Model	Yaklaşık Zaman Karmaşıklığı
ResNet-50	$O(n \times 25e9)$
ResNet-101	$O(n \times 44e9)$
InceptionV3	$O(n \times 5.7e9)$
Inception	$O(n \times 5.0e9)$
VGG-19	$O(n \times 19.6e9)$
VGG-16	$O(n \times 15.3e9)$
EfficientNet-B7	$O(n \times 37e9)$
EfficientNet-B2	$O(n \times 1.0e9)$
EfficientNetV2	$O(n \times 24e9)$
EfficientNetV2-L	$O(n \times 55e9)$
MobileNetV2	$O(n \times 0.3e9)$
DenseNet-121	$O(n \times 2.9e9)$
DenseNet-201	$O(n \times 4.3e9)$
AlexNet	$O(n \times 0.7e9)$
Xception	$O(n \times 8.4e9)$
AlexNet + SVM	$O(n \times 0.7e9)$
AlexNet + Softmax	$O(n \times 0.7e9)$
AlexNet + Deep kNN	$O(n \times 0.8e9)$

3.3. Algoritma Performanslarının Veri Türüne Bağlı Olarak Değerlendirilmesi


İncelenen çalışmalarda kullanılan veri türleri, göre Tablo 1 ve Tablo 2’de Veri Türü başlığı altında sunulmuştur. Bu bağlamda, yapılandırılmış veri ve görüntü veri türleri algoritma performanslarına göre analiz edilmiş; her iki veri türü için de doğruluk değeri en yüksek ilk 5 algoritma belirlenmiş ve sonuçlar Tablo 6 ve Tablo 7’de belirtilmiştir.

Tablo 6. Görüntü Verisi İçin En Başarılı İlk 5 Algoritma


Algoritma	Başarı (%)
ResNet-50	100
CatBoost	99,8
VGG-19	99,71
CNN	99,67
AlexNet + Softmax	99,52

Tablo 7. Yapılandırılmış Veri İçin En Başarılı İlk 5 Algoritma

Algoritma	Başarı (%)
Destek Vektör Makinesi (Thabit, 2023)	99,1
Rastgele Orman	99,26
Lojistik Regresyon	98,25
XGBoost	98,24
Destek Vektör Makinesi (Mishra ve Agarwal, 2022)	98

**Şekil 2. Akciğer kanseri için doğruluk değerlerinin grafik üzerinde gösterimi**

Şekil 2 'deki grafikte, çeşitli yapay zekâ modellerinin, akciğer kanseri vakalarını doğru bir şekilde teşhis etme oranları gösterilmektedir. İncelenen çalışmalarda elde edilen bulgular ışığında, akciğer kanseri tanısında en başarılı yapay zekâ modeli %100 doğruluk oranıyla vakaların tümünü doğru bir şekilde teşhis eden ResNet50 modelidir. ResNet50 modelini takip eden, %99,80 doğruluk oranıyla CatBoost ve %99,71 doğruluk oranıyla VGG19 modeli olarak belirtilmektedir. İncelenen birçok yapay zekâ modelinin akciğer kanseri teşhisi konusunda yüksek başarı sağladığı görülmektedir.



Şekil 3. Meme kanseri için doğruluk değerlerinin grafik üzerinde gösterimi

Şekil 3’deki grafikte farklı yapay zekâ modellerinin, meme kanseri vakalarını tespit etmedeki başarı oranları sergilenmektedir. Yapılan analizler sonucunda, incelenen yapay zekâ modelleri arasında en yüksek başarı oranını %99,67 ile CNN modeli göstermiştir. Bu başarıyı %99,41 ile Destek Vektör Makinesi ve %99,26 ile Rastgele Orman modeli takip etmektedir. Araştırma kapsamı dahilinde ele alınan çalışmaların büyük bir çoğunluğu grafiklerle desteklenen verilere dayanarak yapay zekâ modellerinin meme kanseri tanısındaki potansiyelini açıkça ortaya koymaktadır.

3.4. LLM

LLM, geniş ölçekli bir dil yelpazesine sahip olacak şekilde eğitilmiş bir yapay zekâ modelidir. Büyük ölçekli sinir ağları tarafından desteklenen bu modeller; metin tabanlı verileri anlamlandırma, metin oluşturma, metin özetleme, soru-cevap sistemleri, çeviri ve önerilerde bulunma gibi çeşitli özelliklere sahiptir. Tıp da dahil olmak üzere birçok endüstride yeni olanaklar yaratma potansiyeline sahip olan LLM’in kanser alanında da kullanılabilecek çok yönlü yetenekleri mevcuttur (Naik ve ark., 2024).

Onkoloji literatüründeki güncel çalışmalardan bilgi elde edilebileceği ve bu bilgiler doğrultusunda sağlık profesyonellerine güncel bulgular hakkında bilgi sağlayabilme potansiyeline sahiptir. Hem hasta hem sağlık profesyonellerinin yararlanabileceği bir soru-cevap platformu oluşturulup ilgili rahatsızlığa yönelik semptomlar veya tedavi seçenekleri hakkında bilgi edinilebileceği öngörülmektedir. Büyük ölçekli veri seti analizi ile kanser riskini artırıp azaltan faktörlerin belirlenebileceği, belirli bir kanser türünün zaman içindeki değişiminin incelenebileceği ve bu sayede kanserle mücadele stratejisinde olumlu gelişmelerin izlenmesine katkıda bulunabilir.

3.5 LVM

LVM’ler, görsel verilerden anlamlı bilgi çıkarma konusunda uzmanlaşmış derin öğrenme modelleridir. Büyük miktardaki parametreleri ve hiyerarşik özellik çıkarma yetenekleri sayesinde, geniş ölçekli veri setlerindeki karmaşık görsel özellikleri tanıyarak bilgisayarla görü alanında önemli gelişmeler sağlamaktadır. LVM’ler kapsamlı bir eğitim aşamasından geçmektedir. Eğitim sürecinde özellikle

görüntü tanıma problemlerinde yüksek performans gösteren Evrişimsel Sinir Ağları kullanılır bununla birlikte LVM'ler kademeli olarak özellik çıkaran çok sayıda katmana sahiptir. Etiketli görüntülerden oluşan kapsamlı veri setleri ile beslenen model, çeşitli görsel işlevlerde verimli olarak kullanır hale gelmektedir. Tarımdan eğlence sektörüne kadar geniş iş sahaları üzerinde etkinlik gösteren LVM'lerin tıp alanında kullanımı da oldukça önemli bir rol oynamaktadır.

Onkoloji için çeşitli kullanım alanlarına sahip olan LVM'lerin BT taramalarını, MR görüntülerini ve diğer tıbbi görüntüleri analiz etmesi ile kanserli lezyon teşhisinin ve yayılma derecesinin saptanması mümkündür. LVM'ler ile patolojik histoloji örneklerini ele almak sadece kanser değil çeşitli hastalıkların doku ve hücrelerde oluşturduğu değişimlerin tespiti için de büyük önem taşımaktadır. Değişimlerin zaman içinde gözlemlenmesi ile de hastalık progresyonunun takibinin yapılabileceği düşünülmektedir. LVM'ler aracılığıyla kanserin nedeni ve gelişimi genetik ve klinik veriler ile ele alınabilir ve olası biyobelirteçler belirlenerek tedavi yöntemlerinin planlanma süreci için optimizasyon sağlanabileceği öngörülmektedir.

4. Sonuçlar

Bu çalışmada akciğer ve meme kanseri teşhisi için derin öğrenme ve makine öğrenimi temelli algoritmaların performanslarını değerlendirmeyi amaçlamaktadır. İncelenen çalışmaların özetlenmesiyle birlikte, yapay zekâ modellerinin kullanımında belirgin bir çeşitlilik gözlemlenmektedir; bazı modeller yaygın olarak kullanılırken diğerleri daha az rağbet görmekte ve düşük oranlarda kullanılmaktadır.

Akciğer kanseri teşhisi bağlamında incelenen sekiz çalışmada elde edilen doğruluk oranı %83 ile %100 arasında seyretmektedir. Bu kapsamda ele alınan çalışmalarda yirmi iki farklı yapay zekâ modeli kullanılmaktadır. En yüksek başarı oranına ResNet-50 modeli ile ulaşılrken, en düşük başarı oranına sahip model EfficientNetB2 olarak gözlemlenmektedir.

Meme kanseri teşhisi açısından ise araştırmaya dahil edilen yirmi iki çalışmanın doğruluk oranı %89 ile %99,67 arasında değişmektedir. Meme kanseri teşhisi için dikkate alınan çalışmalarda otuz farklı yapay zekâ modeli kullanıldığı belirlenmiştir. En yüksek başarı oranına sahip model CNN iken en düşük başarıya sahip model Xception olarak gözlemlenmektedir.

Literatür taramasının ardından gerçekleştirilen LLM'ler ve LVM'lerin onkoloji alanında kullanımı incelenmiş ve mevcut bilgilerin analiz edilmesi ile bu modellerin onkoloji alanında etkili bir şekilde kullanılabileceği konusunda çeşitli önerilerde bulunulmuş aydınlatıcı bir perspektif sunulmuştur.

Sonuç olarak bu çalışma yapay zekâ modellerinin tıbbi teşhis süreçlerine entegrasyonunu akciğer ve meme kanseri teşhisi üzerinden ele alıp bu süreçlerdeki etkinliğinin durumunu değerlendirmektedir. Bununla birlikte LLM'ler ve LVM'ler üzerine yapılan inceleme ile gelecekteki araştırmalar için yol gösterici bir çerçeve sunulması amaçlanmıştır. Modellerin klinik uygulamalarda kullanımının yaygınlaştırılması için daha fazla validasyon çalışmasına ihtiyaç duyulduğu düşünülmektedir. İlgili teknolojilerin kullanımlarının artması ile birlikte daha başarılı analiz yeteneğinin oluşacağı ve bu

sayede yeni tedavi stratejilerinin geliřebileceđi ve teřhis sũreçlerinde iyileřtirmelerin gerçekteřebileceđi sonucuna varılmaktadır.

Çıkar Çatıřması Beyanı

Makale yazarları herhangi bir çıkar çatıřması olmadığını beyan eder.

Arařtırmacıların Katkı Oranı Beyan Özeti

Yazarlar makaleye eřit oranda katkı sađlamıřtır.

Kaynakça

- Akash MB. Improved breast cancer detection using machine learning. *International Journal of Scientific Research in Engineering and Management* 2024; 8(5): 1-5.
- Ak MFA comparative analysis of breast cancer detection and diagnosis using data visualization and machine learning applications. *Healthcare* 2020; 8(2): 111.
- Akbar W., Soomro A., Ghanghro SA., Haq MIU., Ullah M. Performance evaluation of deep learning models for breast cancer classification. *2023 IEEE International Conference on Emerging Trends in Engineering, Sciences and Technology (ICES&T)*, 9-11 Ocak 2023, sayfa no:1-4, Bahawalpur, Pakistan.
- Allugunti VR. Breast cancer detection based on thermographic images using machine learning and deep learning algorithms. *International Journal of Engineering in Computer Science* 2022; 4(1): 49-56.
- Altan G. Deep learning-based mammogram classification for breast cancer. *International Journal of Intelligent Systems and Applications in Engineering* 2020; 8(3): 171-176.
- Alomar A., Alazzam M., Mustafa H., Mustafa A. Lung cancer detection using deep learning and explainable methods. *2023 14th International Conference on Information and Communication Systems (ICICS)*, 21-23 Kasım 2023, sayfa no:1-4, Irbid, Ürdün.
- Benhassine NE., Boukaache A., Boudjehem D. A new CAD system for breast cancer classification using discrimination power analysis of wavelet coefficients and support vector machine. *Journal of Mechanics in Medicine and Biology* 2020; 20(06): 2050036.
- Bouamrane A., Derdour M. Enhancing lung cancer detection and classification using machine learning and deep learning techniques: A comparative study. *2023 International Conference on Networking and Advanced Systems (ICNAS)*, 21-23 Ekim 2023, sayfa no:1-6, Cezayir.
- Çifçi M. Derin öğrenme metodu kullanarak BT görüntülerinden akciđer kanseri teřhisi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi* 2022; 24(71): 487-500.
- Das N., Borah J., Sarmah K. Diagnosis and classification of breast cancer using multiple machine learning algorithms. *2023 International Conference on Advancement in Computation & Computer Technologies (InCACCT)*, 5-6 Mayıs 2023, sayfa no:221-226, Gharuan, Hindistan.

- Dirik M. Machine learning-based lung cancer diagnosis. *Turkish Journal of Engineering* 2023; 7(4): 322-330.
- Aziz A., Hussain SK., Ramay SA., Arshad R., Niazi M., Mushtaq Z., Ibrahim U., Khan AA., Afzal MB. Machine learning approaches for early detection of lung cancer. *Journal of Computing & Biomedical Informatics* 2023; 6(1): 407–418.
- International Agency for Research on Cancer. IARC. <https://www.iarc.who.int/> (Erişim Tarihi: 29 Ağustos 2024).
- Iqbal HN., Bou Nassif A., Shahin I. Classifications of breast cancer diagnosis using machine learning. *International Journal of Computers* 2020; 14: 86-86.
- Kadhim RR., Kamil MY. Comparison of machine learning models for breast cancer diagnosis. *IAES International Journal of Artificial Intelligence* 2023; 12(1): 415.
- Lathakumari KR., Ramachandra AC., Avanthi UC., Ronald CB., Bhavatharani T. Classification of non-small cell lung cancer using deep learning. 2023 International Conference on Applied Intelligence and Sustainable Computing (ICAISC), 16-17 Haziran 2023, sayfa no:1-5, Dharwad, Hindistan.
- Lee M., Sun Z. Machine learning methods for breast cancer diagnosis. *Journal of Student Research* 2022; 11(3).
- Mahmud MI., Mamun M., Abdelgawad A. A deep analysis of transfer learning based breast cancer detection using histopathology images. 2023 10th International Conference on Signal Processing and Integrated, 23-24 Mart 2023, sayfa no:198-204, Noida, Hindistan.
- Mahoro E., Akhloufi MA. Breast cancer classification on thermograms using deep CNN and transformers. *Quantitative InfraRed Thermography Journal* 2024; 21(1): 30-49.
- Mangukiya M., Vaghani A., Savani M. Breast cancer detection with machine learning. *International Journal for Research in Applied Science and Engineering Technology* 2022; 10(2): 141-145.
- Manjunathan N., Gomathi N., Muthulingam S. Early detection of breast cancer using machine learning. 2023 International Conference on Sustainable Computing and Smart Systems (ICSCSS), 14-16 Haziran 2023, sayfa no:165-169, Coimbatore, Hindistan.
- Mishra S., Agarwal BM. Diagnosis and classification of cancer using machine learning techniques. 2022 IEEE International Conference on Service Operations and Logistics, and Informatics (SOLI), 2-4 Aralık 2022, sayfa no:1-5, Delhi, Hindistan.
- Mohalder RD., Sarkar JP., Hossain KA., Paul L., Raihan M. A deep learning based approach to predict lung cancer from histopathological images. 2021 International Conference on Electronics, Communications and Information Technology (ICECIT), 14-16 Eylül 2021, sayfa no:1-4, Khulna, Bangladeş.
- Naik N., Khandelwal A., Joshi M., Atre M., Wright H., Kannan K. Applying large language models for causal structure learning in non-small cell lung cancer. 2024 IEEE 12th International

- Conference on Healthcare Informatics (ICHI), 3-6 Haziran 2024, sayfa no:688-693, Orlando, FL, ABD.
- Naji MA., El Filali S., Aarika K., Benlahmar EH., Ait Abdelouhahid R., Debauche O. Machine learning algorithms for breast cancer prediction and diagnosis. *Procedia Computer Science* 2021; 191: 487-492.
- Peng CC., Wu JW. Deep learning-assisted lung cancer diagnosis from histopathology images. 2023 IEEE 5th Eurasia Conference on Biomedical Engineering, Healthcare and Sustainability (ECBIOS), 2-4 Haziran 2023, sayfa no:17-20, Tainan, Tayvan.
- Promptan S., Khongthong P., Choksuchat C. Breast cancer prediction of benign and malignant tumors by classification algorithms. 2023 4th International Conference on Big Data Analytics and Practices (IBDAP), 25-27 Ağustos 2023, sayfa no:1-6, Bangkok, Tayland.
- Salama WM., Aly MH. Deep learning in mammography images segmentation and classification: Automated CNN approach. *Alexandria Engineering Journal* 2021; 60(5): 4701-4709.
- Sayın İ., Soydaş MA., Mert YE., Yarkataş A., Ergun B., Sözen Yeh S., Üvet H. Comparative analysis of deep learning architectures for breast cancer diagnosis using the BreacKHis dataset. arXiv preprint, arXiv:2309.01007.
- Subramanian RR., Mourya RN., Reddy VP., Reddy BN., Amara S. Lung cancer prediction using deep learning framework. *International Journal of Control and Automation* 2020; 13(3): 154-160.
- Telsang VA., Hegde K. Breast cancer prediction analysis using machine learning algorithms. 2020 International Conference on Communication, Computing and Industry 4.0 (C2I4), 17-18 Aralık 2020, sayfa no:1-5, Bangalore, Hindistan.
- Thabit QQ. Deep and machine learning for improving breast cancer detection. *Engineering and Technology Journal* 2023; 8(12): 3156-3163.
- Veranyurt Ü., Deveci A., Esen MF., Veranyurt O. Makine öğrenmesi teknikleriyle hastalık sınıflandırması: Random forest, k-nearest neighbour ve adaboost algoritmaları uygulaması. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi* 2020; 6(2): 275-286.
- Zhou Z. Breast cancer diagnosis with machine learning. 4th International Conference on Computer Engineering, Information Science and Internet Technology (CII 2022), *Highlights in Science, Engineering and Technology* 2022; 9: 73-75.