

Tüberküloz Hastalığının Tespiti için Derin Öğrenme Yöntemlerinin Karşılaştırılması

Çiğdem BAKIR^{1*}, Mehmet BABALIK²

¹Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 43000, Kütahya

²Kütahya Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43000, Kütahya

¹<https://orcid.org/0000-0001-8482-2412>,

²<https://orcid.org/0000-0002-1473-0157>

*Sorumlu yazar: cigdem.bakir@dpu.edu.tr

Araştırma Makalesi

Makale Tarihiçesi:

Geliş tarihi: 13.08.2023

Kabul tarihi: 13.04.2024

Online Yayınlanma: 16.09.2024

Anahtar Kelimeler:

Evrişimsel sinir ağı

Tüberküloz

VGG19

Yapay sinir ağları

Transfer öğrenme

ÖZ

Yapay zeka, sağlık alanında kanser gibi birçok hastalığın teşhis edilmesinde, doktorlar tarafından yapılan tetkiklerde, cihazlarla gerçekleştirilen tanı ve tedavilerde sıklıkla kullanılmaktadır. Çünkü doktorlar herhangi bir hastalığın doğru tanı ve doğru teşhisini manuel olarak ortaya koymak gerek zaman gerekse maliyet açısından oldukça zordur. Bu hastalıklardan en önemlisi olan tüberküloz (verem), dünyanın birçok yerinde sonu ölümlle sonuçlanan bulaşıcı ve tehlikeli hastalıklardan biridir. Tüberküloz için uzman radyologlar göğüs röntgenlerine bakarak teşhis koyarlar. Fakat radyologlar bu teşhisi koyarken kimi zaman çok sayıda göğüs röntgeni inceledikleri için yanlış tanı ve teşhis koyabilmektedir. Bu durumda manuel bir teşhis yerine daha hızlı ve daha doğru kararlar verebilen bilgisayar destekli analizler gerekmektedir. Bu çalışmanın amacı yapay zekâ yöntemleri kullanılarak akciğer röntgen verilerinden tüberkülozlu ve sağlıklı görüntülerin otonom olarak tespiti ve sınıflandırılmasını yapacak bir model oluşturmaktır. Bu çalışmada tüberküloz hastalığının bilgisayar destekli analiz ve tespitini gerçekleştirmek amacıyla yapay zekanın bir alt kümesi olan derin öğrenme metotlarından Yapay Sinir Ağları (ANN), Evrişimsel Sinir Ağları (CNN) ve çeşitli transfer öğrenme modelleri kullanılmıştır. Önerilen modelinin ilk aşamasında akciğer röntgen filmlerinden elde edilen 1000 görüntüden Çekişmeli Üretici Ağ (GAN) gibi veri artırma yöntemleri ile sentetik görüntüler oluşturulmuştur. Görüntüler 5 farklı senaryoya göre etiketlenmiştir. Görüntülerin doğru, hızlı ve minimum maliyetle teşhisi için farklı ve yeni ağ yapısı oluşturularak verilerdeki önemli öznitelikler belirlenmiştir. Ayrıca önerilen CNN ve Yapay Sinir Ağları (Artificial Neural Network –ANN) modeli doğruluk, duyarlılık, kesinlik ve F1-Skor gibi farklı değerlendirme metrikleri kullanılarak detaylı bir şekilde karşılaştırılmıştır. Kullanılan her model için de performans analizleri gerçekleştirilmiştir. Bu çalışmada CNN ve ANN modelinin sınıflandırma başarısı sırasıyla %98,91 ve %90,41 olarak bulunmuştur. Önerilen CNN modeli ANN modeline göre tüberküloz hastalığının doğru teşhis ve sınıflandırılmasında daha başarılı sonuçlar vermiştir. Önerilen modellerin başarısı ön eğitilmiş modellerin başarısı ile karşılaştırılmıştır ve farklı çapraz doğrulama değerlerine göre başarısı hesaplanmıştır.

Comparison of Deep Learning Methods for Detection of Tuberculosis Disease

Research Article

Article History:

Received: 13.08.2023

Accepted: 13.04.2024

Published online: 16.09.2024

ABSTRACT

Artificial intelligence is frequently used in the field of healthcare to diagnose many diseases such as cancer, in examinations performed by doctors, and in diagnoses and treatments performed with devices. Because it is very difficult for doctors to manually diagnose any disease in terms of both time and cost.

Keywords:

Convolutional neural network
Tuberculosis
VGG19
Artificial neural networks
Transfer learning

Tuberculosis, the most important of these diseases, is one of the infectious and dangerous diseases that results in death in many parts of the world. Specialist radiologists diagnose tuberculosis by looking at chest x-rays. However, when making this diagnosis, radiologists can sometimes make the wrong diagnosis because they examine many chest X-rays. In this case, instead of a manual diagnosis, computer-aided analyzes that can make faster and more accurate decisions are required. The aim of this study is to create a model that will autonomously detect and classify tuberculosis and healthy images from lung x-ray data using artificial intelligence methods. In this study, Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN) and various transfer learning models, which are deep learning methods that are a subset of artificial intelligence, were used to perform computer-aided analysis and detection of tuberculosis disease. In the first stage of the proposed model, synthetic images were created from 1000 images obtained from lung x-ray films using data augmentation methods such as Adversarial Generative Network (GAN). Images are labeled according to 5 different scenarios. Important attributes in the data were determined by creating a different and new network structure for accurate, fast and minimum cost diagnosis of images. Additionally, the proposed CNN and Artificial Neural Network (ANN) model was compared in detail using different evaluation metrics such as accuracy, sensitivity, precision and F1-Score. Performance analyzes were carried out for each model used. In this study, the classification success of the CNN and ANN models was found to be 98.91% and 90.41%, respectively. The proposed CNN model gave more successful results in accurate diagnosis and classification of tuberculosis disease than the ANN model. The success of the proposed models was compared with the success of pre-trained models and their success was calculated according to different cross-validation values.

To Cite: Bakır Ç., Babalık M. Tüberküloz Hastalığının Tespiti için Derin Öğrenme Yöntemlerinin Karşılaştırılması. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 2024; 7(4): 1635-1665.

1. Giriş

Tüberküloz (TB), genellikle akciğerleri etkileyen tehlikeli, bulaşıcı, zehirli ve ölümcül bir hastalıktır. Göğüs bölgesinin yanı sıra lenf ve beyin gibi diğer organları da etkileyebilen karmaşık bir hastalık olarak kabul edilmektedir. Akciğer tüberkülozuna sahip olan bireyler, öksürme ve konuşma gibi basit eylemlerle hastalığı kolaylıkla sağlıklı insanlara bulaştırabilirler. Bu nedenle tehlikeli kabul edilirler. Ayrıca, beslenme yetersizliği ve zayıf bağışıklık sistemi gibi durumları olan insanların savunma dirençleri düşüktür (Lakhani ve ark., 2017).

Tıbbi teşhis (tanı), bir hastalığın veya sağlık sorununun belirlenmesi ve adlandırılması sürecidir. Bu süreçte, bir hekim veya sağlık uzmanı, hastanın semptomlarını değerlendirir, tıbbi geçmişini inceler, fiziksel muayene yapar ve gerekli görülmesi durumunda laboratuvar testleri, görüntüleme yöntemleri veya diğer tanı araçlarına başvurur. Tıbbi tanı, bir hastalığın doğru bir şekilde belirlenmesi için klinik bulguların ve laboratuvar sonuçlarının birleştirilmesini gerektirir. Tıbbi tanının (teşhis) başarı derecesi; doğru hasta değerlendirmesi, klinik deneyim, tanı araçları, iletişim becerileri ve hasta uyumu gibi faktörlerin bir kombinasyonuna bağlıdır. Bu faktörlerin optimal bir şekilde bir araya gelmesi, doğru ve etkili bir tıbbi tanı konulmasını sağlar (Pardue ve ark., 1994).

Araştırmacılar, her geçen yıl yanlış veya geç teşhis sayısının arttığı ve bunların dünya genelindeki insanların ölümüne yol açtığını belirtmektedir ((Woolever, 2005; Gruson ve ark., 2019). Örnek olarak, Amerika Birleşik Devletleri'nde meydana gelen ölümler incelendiğinde, tıbbi hatalarla ilişkili ölümlerin

kardiyovasküler hastalıklar ve kanserden sonra üçüncü sırada geldiği tespit edilmiştir. Erken teşhis konan hastaların tedavi başarısı genellikle zamanında yapılan teşhise bağlı olarak artmaktadır. Ayrıca, erken tanı konan hastaların rehabilitasyon maliyetleri, geç teşhise göre daha düşüktür.

Araştırmalar, doğru ve zamanında teşhisin önemini vurgulamaktadır. Yanlış veya geç teşhislerin ciddi sonuçlara yol açabileceği, hastaların tedavi şansını azaltabileceği ve hatta ölümlerle sonuçlanabileceği gözlemlenmiştir. Özellikle ölümcül hastalıkların erken evrelerinde tanının konulması, tedavi seçeneklerinin daha etkili olmasını sağlayabilir ve hastaların sağ kalım oranını artırabilir. Tıbbi hataların kaynakları arasında yeni hastalıkların ortaya çıkması, yetersiz araştırma çalışmaları ve doğru karar vermeyi destekleyen araçların eksikliği önemli rol oynamaktadır. Bu nedenlerle, sürekli olarak yeni hastalıkların incelenmesi, tıp alanında daha fazla araştırma yapılması ve doktorlara doğru teşhis koymada yardımcı olacak teknolojilerin geliştirilmesi büyük önem taşımaktadır (Pannu, 2015). Karmaşık hastalıkların bazılarında doğru bir teşhis koymak oldukça zor ve bazen imkânsız hale gelebilmektedir. Bu nedenle, araştırmacılar, özellikle iş, mühendislik, tıp gibi önemli alanlarda karar destek sistemlerinin kullanımıyla ilgilenmektedir. Bu sistemler, doktorlara teşhis sürecinde yardımcı olabilir ve daha doğru kararlar almalarını sağlayabilir (Angeli, 2010).

Günümüzde, doktorların hastalıkları teşhis etme ve karar verme süreçlerinde yardımcı olan güçlü araçlar arasında karar destek sistemleri önemli bir yer tutmaktadır. Karar destek sistemleri, doktorlara daha kolay bir şekilde tanı koymalarına yardımcı olacak birçok çalışma üzerine odaklanmıştır. Bu bağlamda, uzman sistemler, derin öğrenme ve yapay zekâ teknikleri, çeşitli tıp branşlarında farklı problemlerin çözümünde başarıyla kullanılmaktadır. Bu sistemler, doktorlara klinik verileri analiz etme, teşhis koyma sürecinde destek sağlama ve tedavi seçeneklerini değerlendirme konusunda yardımcı olmaktadır. Karar destek sistemlerinin kullanımı, hastaların daha hızlı ve doğru teşhis almasına, tedavi süreçlerinin iyileştirilmesine ve sağlık hizmetlerinin etkinliğinin artırılmasına katkıda bulunmaktadır (Er ark., 2010). Birçok hastalık, insan sağlığını yaşam sürekliliği ve kalitesi açısından tehdit ederek farklı yönlerden etkileyebilir. Bu hastalıklar arasında, tüberküloz (TB), kronik obstrüktif akciğer hastalığı (COPD - KOAH), zatürre, astım ve akciğer kanseri gibi göğüs hastalıkları hem gelişmekte olan ülkelerde hem de gelişmiş ülkelerde ciddi sağlık komplikasyonları ve ölüm nedenleri arasında öncelikli yer almaktadır. Göğüs hastalıkları, solunum sistemini etkileyen ve solunum fonksiyonlarını olumsuz etkileyen rahatsızlıklardır. Tüberküloz gibi bulaşıcı hastalıklar, özellikle düşük gelirli ülkelerde yaygın olarak görülmektedir ve önemli bir halk sağlığı sorunu teşkil etmektedir. Kronik obstrüktif akciğer hastalığı (KOAH), Zatürre, astım ve akciğer kanseri gibi hastalıklar da ciddi sağlık sorunlarıdır ve dünya genelinde önemli ölüm nedenleri arasında yer almaktadır (Er ve ark., 2010).

Tüberküloz, Dünya Sağlık Örgütü'ne göre dünya genelinde çok sayıda ölüme sebep olan 10 hastalıktan biri olarak kabul edilmiştir. Bulaşıcı bir şekilde hızla yayılan bu hastalık erken tanı konulup tedavi edilmezse başta ölüm olmak üzere göğüs hastalıkları, nefes darlığı gibi birçok sağlık sorununa yol açmaktadır. Tüberküloz hastalığının bulaşıcı etkisini azaltmak, ölüm oranını en aza indirmenin en önemli adımı erken teşhis ve tedavidir. Erken teşhis, akciğer röntgen filmlerinde hastalığın tespit

edilmesi ile gerçekleşir. Bunun için de yapay zeka ve derin öğrenme yöntemlerini içeren bilgisayar destekli analizlere ihtiyaç duyulmaktadır. Bilgisayar destekli analiz için kullanılan bu yöntemler ile tüberküloz hastalığının tespiti, erken tanı konulması, tedavi sürecinin uygulanması, hastanın durumunu izleme ve kişiye uygun ilaçlar üretilir. Yapay zeka yöntemleri hasta bakımı, tıbbi görüntülerin belirlenmesi, ilaç geliştirme, cerrahi planlama ve ilaç önerme gibi birçok alanda kullanılmaktadır. Böylelikle büyük hacme sahip elektronik sağlık verileri hastalığın önlenmesi için analiz edilir (Elveren ve ark., 2011).

Bizim çalışmamızda, doktorların tüberküloz (TB) hastalığını röntgen görüntüleri üzerinden teşhis etmesine yardımcı olmak için bazı yapay zeka tekniklerini kullanan karar destek sistemlerinin kullanılması üzerinde çalışılmıştır. Bu tekniklerden Yapay Sinir Ağları (Artificial Neural Network – ANN) ve Evrişimli Sinir Ağları, (Convolutional Neural Network - CNN) ve hibrit (VGG19+CNN) model kullanılarak sınıflandırma yapılmıştır. Hastalık sınıflandırması için farklı ağ yapısına sahip sinir ağı modellerin oluşturulması, eğitim ve test kümelerinin belirlenmesi, ağın eğitimi, test görüntü kümelerinin farklı değerlendirme kriterleri ile performansının ölçülmesi, modellerin değerlendirilmesi, karşılaştırılması tez kapsamında ele alınmıştır. Önerilen yöntemler Kaggle veritabanından alınan bir veri kümesi kullanılarak değerlendirilmiştir. Önerilen CNN ve VGG19+CNN modeli yapay sinir ağları ile karşılaştırılmıştır. Bu çalışmada, doktorların röntgen görüntüleri üzerinden tüberküloz (TB) hastalığına tanı ve teşhis etmesini sağlamak için bazı derin öğrenme modellerini kullanan karar destek sistemlerinin geliştirilmesi amaçlanmıştır. Yapılan çalışmada Yapay Sinir Ağları (Artificial Neural Network - ANN), Evrişimsel Sinir Ağları (Convolutional Neural Network - CNN) ve hibrit model (VGG19 + CNN) kullanılarak sınıflandırma yapılmıştır. Hastalık sınıflandırması için farklı ağ yapısına sahip sinir ağı modellerin oluşturulması, eğitim ve test kümelerinin belirlenmesi, ağın eğitimi, test görüntü kümelerinin farklı değerlendirme kriterleri ile performansının ölçülmesi, modellerin değerlendirilmesi, karşılaştırılması ele alınmıştır. Önerilen CNN ve VGG19+CNN modeli yapay sinir ağları ile karşılaştırılmıştır.

Çalışmamızın bilimsel katkısı CNN'nin ağ ve katman yapısını kendimiz oluşturarak modelin başarısını arttırdık. Ayrıca GAN gibi veri arttırma teknikleri ile oluşturulan sentetik veriler oluşturulmuştur ve farklı sayıda etiketlenmiş görüntüler üzerinde önerilen modellerin başarısı hesaplanmıştır. Böylelikle başarı ve performans artırılmıştır ve bu çalışma ileride yapılacak olan farklı hastalık türlerinin tespit edilmesinde önemli katkılar sağlayacaktır.

2. İlgili Çalışmalar

Günümüzde tüm dünyada COVID-19 sağlık ve ekonomiyi olumsuz etkilemiştir. COVID-19 akciğer kanseri, tüberküloz ve pnömi gibi birçok göğüs hastalıkları ile benzer semptomlar içermektedir ve ileride bu hastalıklara neden olmaktadır. Malik ve arkadaşları Covid-19'un akciğer hastalıklarına vermiş olduğu yıkıcı etkileri en aza indirmek amacıyla CDC Net adlı bir evrişimli sinir ağı kullanarak bir model geliştirmişlerdir (Malik ark., 2023). Bu model ile COVID-19 erken aşamada teşhisi edilmesi

hedeflenmiştir. Göğüs röntgeni görüntülerinden COVID-19 verileri sınıflandırılmıştır. Sınıflandırma doğruluğu için precision, recall, F1 Score metrikleri kullanılmıştır. Ancak radyoloji sistemlerinin entegrasyonu, bakımı, çekilen röntgen filmlerinin kalitesi ve kullanılabilirliği aşamasında modelin iyileştirilmesi için birçok sorunlar ortaya çıkmaktadır.

Dünya Sağlık Örgütüne göre tüberküloz ve COVID-19 birçok insanın ölümüne sebep olan çok ciddi hastalıklardır. Bu hastalıkların belirtileri arasında hışırtı, öksürme ve nefes darlığı semptomlar görülmektedir. Bu semptomları belirlemek amacıyla Karaddi ve arkadaşları CNN ağı kullanarak bir çalışma gerçekleştirmişlerdir (Karaddi ark., 2023). Bu akciğer hastalıklarını tanımlamaya ve kategorize etmek amacıyla göğüs röntgeni görüntü veri seti kullanmışlardır. Yapılan çalışmada Alexnet, Darknet-19, Darknet-53, Densenet-201, Googlenet, InceptionResnetV2, MobilenetV2 ve Resnet-18 gibi ağlar kullanılması tavsiye edilmektedir. Eğitim aşamasında 30 epoch ve adam optimizere kullanmışlardır. Akciğer hastalıklarıyla ilgili daha hızlı ve doğru sınıflandırma ve tespit edilmesi amacıyla daha fazla veriye ihtiyaç duyulmaktadır.

Lestari ve arkadaşları Geri Yayılımlı Yapay Sinir Ağı ile tüberküloz hastalığını tespit etmeye çalışmışlardır (Lestari ve ark., 2023). Geri yayılım algoritması denetimli öğrenme kullanır ve yakınsama düzeyine ulaşmada olumsuz yönleri vardır. Kuzey Sumatra İl Sağlık Müdürlüğünden alınan son 2 yıllık veriler üzerinde çalışma yapmışlardır. %81,82 doğruluk oranı ile başarı sağlamışlardır. Ortalama Kare Hata değerinin öğrenme oranının üzerindeki etkisini gözlemlemişlerdir.

Gichuhi, tüberküloz tedavisinde Lojistik regresyon (LR), yapay sinir ağları (ANN), destek vektör makineleri (SVM), Random Forest (RF) ve AdaBoost modeli kullanmıştır (Gichuhi, 2023). Bu beş model AdaBoost (%91,05), RF (%89,97), LR (%88,30) ve ANN'ye (%88,30) ve SVM %91,28 doğruluk göstermiştir. Yaptıkları çalışmayla makine öğrenimi tekniklerinin tüberküloz tedavisinde hastalık faktörlerini belirlemeyi sağlamıştır.

Lubis ve arkadaşları, HOG (Histogram OF Oriented Gradients) methodu ile tüberküloz görüntülerinin özellik çıkarımını gerçekleştirmişlerdir (Lubis, 2021). Tüberküloz görüntülerin algılanması için KNN (K-En Yakın Komşu) ve SVM (Support Vector Machine) yöntemleri kullanmışlardır. HOG özellikleriyle tüberkülozu tespit etmek ve görüntü şeklindeki verilerin KNN ile saptanmasında %77,95, negatif olanlar ise %77,95 doğruluk elde ederken; SVM ile Tüberküloz Röntgeni sonuçlarında ise HOG tespiti sonuçları pozitif olan görüntülerde %65,75, negatif olanlarda ise %79,39 doğruluk elde etmişlerdir.

Shakya ve arkadaşları 1000 görüntüden oluşan göğüsCT taraması görüntülerinden tüberküloz hastalığının tespitini gerçekleştirmişlerdir (Shakya ve ark., 2022). Çalışmalarında SVM ve KNN sınıflandırıcısı kullanmışlardır. Test sırasında önerilen methodlar için 10 iterasyon uygulamışlardır. SVM yöntemi KNN yöntemine göre daha başarılı sonuçlar vermiştir. Ancak çalışma küçük veriler için uygulanmıştır.

Tüberküloz hastalığı dünyanın birçok yerinde kötü huylu bulaşıcı bir hastalık olarak bilinir. Bu sebeple göğüs röntgen verilerinin doğru ve hızlı olarak sınıflandırılması hastalığın erken tanı ve tedavisinde oldukça önemlidir. Nafisah ve arkadaşları bu amaçla Chest X-Rays (CXR) görüntüleri üzerinde derin öğrenmeye dayalı yöntem kullanmışlardır (Nafisah ark., 2022). Tüberkülozun CXR görüntülerinden tespitinin elde edilmesi için orijinal ve bölümlenmiş görüntüler önerilen modele girdi olarak verilmiştir. ResNet, Inception, Xception, MobileNet ve EfficientNet ile her görüntüden öznetelikler çıkarılmıştır. Modellerin performansı farklı öznetelik ölçütlerine göre değerlendirilmiştir.

Ammar ve arkadaşları, MRI görüntülerini kullanarak tüberküloz hastalığı tanıma için hibrit optimal derin öğrenmeye dayalı bir model kullanmışlardır (Ammar ve ark., 2022). Bu çalışmayla Vision Transformer (ViTs) ve Efficient-Net modelleri ile sınıflandırma doğruluğunu arttırmayı hedeflemişlerdir. Önerdikleri modelin başarısını shenzhen ve montgomery veri seti üzerinde gerçekleştirmişlerdir. Bu çalışmada hibrit derin öğrenme modellerin başarısı değerlendirilmiştir. Ancak derin öğrenme yöntemlerinin parametrelerini farklı veri setleri üzerinde otomatik olarak belirlemek kolay değildir.

Derin öğrenme yöntemleri özellikle sağlık alanında hastalığın doğru ve hızlı tespiti amacıyla sıklıkla kullanılmaktadır. Evrişimli sinir ağı radyoloji ve tomoğrafi gibi birçok alanda yaygın olarak kullanılan derin öğrenme yöntemidir. Venkataramana ve arkadaşları, SMOTE (Sentetik Minority Oversampling Technique) algoritması ile X-ray veya CT tarama görüntülerini arttırmışlardır (Venkataramana ve ark., 2022). Böylelikle sınıfların dağılımlarının dengeli dağıtarak derin öğrenme yöntemlerinin başarısını arttırmışlardır. Ancak farklı göğüs hastalıklarının tespiti için farklı veri artırma yöntemlerinin uygulanması gerekmektedir.

Asakawa ve arkadaşları, tüberküloz için lezyon tespiti için göğüs BT görüntülerinin analizini gerçekleştirmişlerdir (Asakawa ve ark., 2022). ImageCLEF 2022 verisi ile akciğer BT görüntülerinde akciğer kavernaları özellikleriyle ilişkili akciğer kavernalar bölgelerini tespit etmek ve deneyimli radyologlar tarafından önerilen kavernaların üç ikili özelliğini tahmin etmek için CNN modeli önermişlerdir. Birden fazla CNN özelliğinden gelen girdileri kullanmışlardır ve üç etiketli medyan tabanlı tahmin algoritması ile akciğerlerde oluşan lezyonlar belirlenmeye çalışılmıştır.

Rahman ve arkadaşları, COVID-19'un güvenilir ve hızlı bir şekilde tanımlanması, hastalığın hızla yayılmasını önlemek, karantina kısıtlamalarını hafifletmek ve halk sağlığı altyapıları üzerindeki baskıyı azaltmak için farklı görüntü ve veriler kullanılarak SARS-CoV-2 virüsünün tespiti için çeşitli yöntem ve teknikler kullanmışlardır (Rahman ve ark., 2022). Bu çalışmada altı farklı derin öğrenme modeli (ResNet18, ResNet50, ResNet101, InceptionV3, DenseNet201 ve MobileNetv2) ve iki sınıflı (normal, COVID-19 olmak üzere) 1937 görüntüden oluşan EKG verileri kullanılmıştır. Çalışmanın amacı, EKG verilerinden COVID-19 ve diğer kardiyovasküler hastalıkları tespit etmektir.

Dünya Sağlık Örgütü, tüberküloz teşhisi için ön ve temel tanı tekniği olarak lekeli balgam yayma örneklerinin görsel olarak incelenmesini önermektedir. Görsel inceleme süreci laboratuvar için çok zaman gerektirir ve hataya açıktır. Ayas ve arkadaşları, bu amaçla otomatikleştirilmiş için yeni bir

rasgele orman (Random-Forest- RF) tabanlı bölümlenme ve sınıflandırma yaklaşımlarını önermişlerdir (Ayas ve ark., 2014). RF tekniği denetimli öğrenme yöntemi, herbir lekelerdeki renk dağılımlarına bağlı olarak her bir pikseli sınıflandırmak için geliştirilmiştir. Bu pikseller bağlantılı bileşen analizi kullanılarak sınıflandırılır. Görünüm tabanlı tüberküloz bakteri tanımlama algoritmalarını kullanmak bir sınırlayıcı kutu içinde merkezi olarak konumlandırılır. Son olarak, eğitim görüntülerinde manuel olarak işaretlenmiş TB bakteri bölgeleri üzerinde eğitilen önerilen RF öğrenme algoritması kullanılarak her bölge sınıflandırılır. Önerilen sınıflandırıcının duyarlılığı ve özgüllüğü piksellerin bölütlenmesi için sırasıyla %75,77 ve %96,97'nin üzerindedir.

Tüberküloz (TB), dünya çapında insan sağlığı için büyük bir tehdit oluşturan ve her yıl milyonlarca ölüme neden olan bulaşıcı bir hastalıktır. Bu hastalığın tedavisinde erken tanı ve teşhis oldukça önemlidir. Bilgisayar destekli teşhis (CAD) hastalığın ölümcül etkilerini azaltılmasında umut verici olmuştur. Yapay zeka ve makine öğrenimi yöntemleri CAD için sıklıkla kullanılmaktadır (Singh ve ark., 2022). Hindistan'da 2006-2014 yılları arasında çok sayıda kişinin ölümüne sebep olan TB hastalığının erken tanı ve teşhisi için %83,78 ve %67,55 hatırlama ve kesinliğe sahip yeni bir Derin Sinir Ağı tabanlı ilaca duyarlı TB tespit metodolojisi önerilmiştir (Kant ve ark., 2018). Bu yöntem, girdi olarak uygun yakınlaştırma düzeyine sahip bir mikroskop görüntüsü ile TB mikroplarının konumunu çıktı olarak döndürür. Böylelikle Hindistan'da ortaya çıkan TB bulaşıcı hastalığının yayılmasının önlenmesi hedeflenmiştir.

Bilgisayar bilimi, modern dinamik sağlık sistemlerinde önemli bir rol oynamaktadır. Teşhis süreci tüm yönleriyle ele alındığında bilgisayar teknolojisi sağlık uzmanlarına ve kuruluşlarına olduğu kadar hastalara, ailelere, araştırmacılara ve karar vericilere önemli hizmetler sunmaktadır. Bu süreci olumlu yönde etki eden tüm yenilikler sağlık hizmetleri alanları için çok önemlidir. Hastalıkların birçoğu ilk aşamada yani erken tanı konulup, teşhis edilirse hastalıklar önlenebilir. Hrizi ve arkadaşları, bu amaçla ImageCLEF 2020 veri setini kullanarak tüberküloz hastalığının tespitini gerçekleştirmişlerdir (Hrizi ve ark., 2022). TB ile ilgili görüntülerden en uygun doku özelliklerini çıkaran ve sınıflandırıcıların hiper parametrelerini seçen optimize edilmiş makine öğrenimi tabanlı bir model geliştirmişlerdir. Doğruluk oranını artırmak ve çıkarılan özellik sayısını en aza indirmek ortaya koymuş olduğu problemlerdir. Optimizasyonu sağlamak amacıyla veri setindeki en önemli özelliklerin seçilmesi gerekmektedir. Bu amaçla genetik algoritma uygulamışlardır ve sınıflandırma için de SVM modeli yaptıkları çalışmada kullanmışlardır. Bu çalışmada tüberküloz (TB) hastalık sınıflandırması problemini ele alınmıştır. SVM sınıflandırıcısının performansını iyileştirmek için genetik algoritmaya dayalı iki yeni teknik kullanılmıştır. İlk teknik için, eğitim ve test aşamalarında mümkün olan en yüksek doğruluğu garanti etmek amacıyla bir dizi değerden en uygun parametreleri belirlemek için uyarlanabilir. İkinci teknik, fazla uydurmayı önlemek ve verilerin boyutunu azaltmak için az sayıda orijinal özelliği seçmektir. Bu çalışmada tartışılan metodoloji, tıbbi görüntü işleme alanında kullanılan birkaç teknik vurgulanmaktadır. Dalgacık dönüşümü, veri setinden özellikleri çıkarmak için uzamsal gri düzey

bağımlılık yöntemiyle kullanılmıştır. Yapılan çalışmayla, çıkarılan özelliklerin kalitesinin görüntü sınıflandırmasının etkinliği üzerinde doğrudan bir etkisi olduğunu gösterilmiştir.

Literatürde yapılan çalışmalarla sağlık alanında hastalık tanı, teşhis ve tedavisinde yapay zeka ve makine öğrenimi tekniklerinin kullanıldığı gösterilmiştir. Yapılan çalışmalar son yıllarda artmakla beraber bu alanda her geçen gün daha da bilgisayar destekli analizin de gerekliliğinin ve ihtiyaç arttığı gözlenmiştir. Tablo 1’de CNN yöntemleriyle farklı veri setleri üzerinde yapılan bazı çalışmalar gösterilmiştir. Bizim çalışmamızda tüberküloz örneklerinin daha doğru ve tutarlı tahmin edilebilmesi amacıyla tüberküloz hastalığı tespit probleminde derin öğrenme tabanlı modeller kullanılmıştır. Diğer çalışmalardan farklı olarak CNN sınıflandırma doğruluğunu arttırmak için özgün bir ağ yapısı oluşturulmuştur. Beş farklı senaryoya göre “tüberkülozlu” ve “sağlıklı” olarak etiketlenen görüntüler için tüm derin öğrenme modellerinin doğruluk sonuçları, k=5 ve k=10 için çapraz doğrulama, doğru olarak tespit edilen “tüberkülozlu” verilerin sayıları gösterilmiştir. Tüberküloz hastalığının bulaşıcı etkisini ve ölüm oranını azaltmak amacıyla bir sınıflandırma modeli geliştirilmiştir. Önerilen bu model, başka hastalıkların tespiti için de bir yol gösterici olma niteliği taşımaktadır. Çalışmamız diğer çalışmalardan farklı olarak tüberküloz hastalığına hem doğru hem hızlı tanı koyarken hem de maliyet açısından düşük maliyete sahiptir.

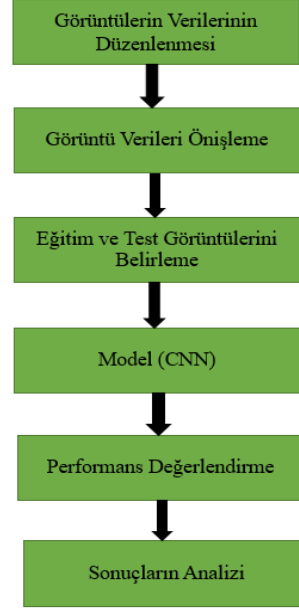
Tablo 1. Literatürde göğüs röntgeni görüntüleri üzerinde CNN ile yapılan çalışmalar

Çalışma	Kullanılan Veri Seti	Doğruluk (%)
Liu, 2017	Peru’da oluşturulan göğüs röntgeni görüntüleri	85,68
Li, 2022	COVIDX8	95,02
Khatri, 2020	-	83,30
Breve, 2022	COVIDx8B	98,15
Hafeez ve ark, 2023	Kaggle COVID-19	97,00
Iqbal ve ark., 2023	Tüberküloz	95,10
Bisht ve ark., 2023	Github COVID-19	87,50
Cao ve ark., 2021	NLM	90,38
Rahman ve ark., 2021	NLM,RSNA,NIAID	96,47

3. Materyal ve Metot

Önerilen modelin iş akış şeması Şekil 1’de gösterilmiştir. Çalışmada kullanılan görüntü verilerinin çeşitli filtreler kullanılarak ön işlemeden geçirilmiştir. Veri ön işleme adımlarında filtreleme, görüntü netleştirme, yumuşatma, gürültü azaltma, normalleştirme ve görüntüyü yeniden boyutlandırma gibi bir dizi ön işleme adımları gerçekleştirilmiştir. Gauss filtresiyle görüntünün gürültüsü giderilmiştir ve


görüntü daha net hale getirilmiştir. Ayrıca görüntü keskinleştirilmiştir. 1000 görüntü verisinin ilk aşamada %70'i eğitim, %30'u test için kullanılmıştır. Daha sonraki aşamalarında farklı eğitim, test ve doğrulama örneklerine ayrılarak önerilen modellerin başarısı test edilmiştir. Önerilen CNN modelinin katmanlı yapısı oluşturularak elde edilen sonuçlar farklı değerlendirme kriterleri ile karşılaştırmalı olarak analiz edilmiştir.



Şekil 1. Önerilen modelin iş akış şeması

3.1. Yapay Sinir Ağları (Artificial Neural Network – ANN)

ANN, insan beyninin işleyişinden ilham alarak oluşturulan ve karmaşık problemleri çözmek için kullanılan bilgisayar tabanlı matematiksel modellerdir. Bu model, birbirleriyle etkileşimli çalışan yapay sinir hücrelerinden (nöronlardan) oluşur ve bilgi işleme ve öğrenme yetenekleriyle dikkat çeker.



Şekil 2. Tek katmanlı ANN temel yapısı

Tek katmanlı ANN yapısı Şekil 2'de gösterilmiştir. Girdi ve çıktı katmanından oluşur. ANN, eğitim süreciyle bilgiyi öğrenir ve çıkarımlar yapar. Eğitim aşamasında, ağa örnek veriler sunulur ve ağ bu

verilere dayanarak parametrelerini günceller. Bu süreçte, ağ hata hesaplar ve bu hataları azaltmaya çalışır. Eğitim süreci tamamlandığında, yapay sinir ağı belirli bir görevi gerçekleştirmek üzere optimize edilmiş hale gelir ve yeni girdilere dayalı sonuçlar üretebilir. ANN, büyük ölçekli ve karmaşık verileri işleyebilme yeteneği sayesinde pek çok alanda kullanım potansiyeline sahiptir (Al-Shayea, 2011). Özellikle yapay zekâ, robotik, otomasyon, tıbbi teşhis, finansal analiz gibi alanlarda önemli bir rol oynamaktadır. Gelişen teknolojilerle birlikte yapay sinir ağları daha da geliştirilecek ve daha karmaşık problemlerin çözümünde daha etkili bir araç haline gelecektir.

Önerilen ANN modelinin parametreleri Tablo 2’de gösterilmiştir. Öğrenme katsayısı için 0,01, 0,001, 0,2, 0,3 denenmiştir ve en uygun öğrenme katsayısı olarak 0,01 seçilmiştir. “Uniform” ağırlığı başlatma fonksiyonu olarak seçilmiştir ve “relu” aktivasyon fonksiyonu ile ağırlık değerlerinin ayarlanmıştır. Çıkış katmanında ise iki sınıflı tübeküloz veri seti için “softmax” aktivasyon fonksiyonu kullanılmıştır. Kayıp fonksiyonu için “categorical_crossentropy” ile hata oranı azaltılmaya çalışılmıştır. Hiper parametrelerin ayarlanması için ince ayarlanması için Adagrad, Stokastik Gradyan İniş (Stochastic Gradient Descent – SGD), Momentum, RMSProp, Adadelta ve Adam optimizasyon algoritmaları kullanılmıştır. “Adam” diğerlerine göre performans ve hız açısından daha başarılı sonuçlar verdiği için çalışmaya “adam” optimizasyon algoritmasının sonuçları verilmiştir. “Adam” algoritması ile önerilen modeller için hiper-parametreleri optimize edilerek en uygun parametreler belirlenmiştir. İleri çalışmalarda rastgele, grid ya da bayes optimizasyonu kullanılarak farklı veriler için daha uygun parametrelerin belirlenip belirlenmeyeceği araştırılacaktır. Önerilen ağ yapısı klasik ağ yapısından farklı oluşturularak modelin sınıflandırma doğruluğunun artırılması hedeflenmiştir. Kullanılan tübeküloz verisine uygulandığında sınıflandırma performansının arttığı gözlemlenmiştir.

3.2. Evrimsel Sinir Ağı (Convolutional Neural Network – CNN)

CNN, derin öğrenme alanında oldukça etkili bir yapay sinir ağı modelidir (Bozkurt, 2023). Özellikle görüntü işleme ve görüntü tanıma gibi alanlarda önemli başarılar elde etmiştir. CNN, beyin tarafından algılanan biçimde, görsel bilgileri işleyebilmek ve karmaşık desenleri tanımlayabilmek için tasarlanmıştır.

CNN’in temel amacı, bir veri kümesindeki özellikleri öğrenmek ve bu özellikleri temsil eden bir model oluşturmaktır. Bu modeller, evrim (convolutional), havuzlama (pooling), tam bağlantılı (fully connected) katmanlar, yoğunluk katmanı, droup katmanı gibi birbirini takip eden katmanlardan oluşur (Sun ve ark., 2017).

Tablo 2. Önerilen modelinin değerleri

Parametreler	Değer
Epoch Sayısı	150
İterasyon Sayısı	80
Aktivasyon Fonksiyonu	relu
Çıkış Katmanı	sigmoid, softmax
Kayıp Fonksiyonu	categorical_crossentropy
Optimizasyon fonksiyonu	adam
Katman Sayısı	5
Nöron Sayısı	25,25,5
Ağırlığı başlatma fonksiyonu	uniform
Diğer optimizasyon fonksiyonları	sgd, nadam, rmsprop, adamax
Diğer aktivasyon fonksiyonları	softplus, tanh, softsign
Grup ölçüsü	5, 10, 15

Evrışim Katmanı (Convolutional Layer): Convolutional Neural Network yapısının temel bir bileşenidir ve görüntü işleme alanında büyük öneme sahiptir. Evrişim katmanı, bir görüntü verisi üzerinde evrişim işlemini uygulayarak, özellik haritalarını oluşturan bir dizi filtre uygular. Evrişim katmanı, bir filtre veya çekirdek matrisini girdi veri üzerinde hareket ettirerek, her konumda bir nokta çarpımı işlemi yapar. Bu nokta çarpımı işlemi, girdi veri ve filtre arasında bir eleman bazında çarpma ve toplama işlemini içerir. Her bir evrişim işlemi sonucunda, bir filtre tarafından algılanan belirli bir özellik elde edilir.

Havuzlama katmanı (Pooling Layer): Convolutional Neural Network (ConvNet ya da CNN) yapısının bir bileşenidir ve genellikle evrişim katmanının ardından gelir. Havuzlama katmanı, girdi verisindeki özellik haritalarını küçültmek ve önemli bilgileri vurgulamak amacıyla kullanılır. Havuzlama katmanı, girdi verisini daha küçük boyutlara indirirken, özelliklerin ölçek, çevrilme ve yer değiştirme değişikliklerine karşı dayanıklılığını artırır. Ayrıca, parametre sayısını azaltarak hesaplama karmaşıklığını azaltır ve ağıın genellemesini geliştirir.

Tam Bağlantılı Katmanlar (Fully Connected Layers): Tam bağlantılı katmanlar, bir yapay sinir ağının (neural network) bileşenlerinden biridir ve genellikle ağıın çıktı katmanına doğru ilerleyen son katmanlardır. Bu katmanlarda, her bir nöron, önceki katmandaki tüm nöronlarla bağlantılıdır. Önceki katmanın tüm çıktılarını alır ve bu çıktıları kendi nöronlarıyla ilişkilendirir. Her bir nöron, girdi olarak

bir ağırlık matrisiyle çarpılan önceki katmanın çıktılarında bir toplam alır. Ardından, bir aktivasyon fonksiyonu tarafından bu toplam değeri aktive edilir ve nöronun çıktısı elde edilir.

Düzleştirici Katman (Flatten Layer): En son katman için (Fully Connected Layer) verileri hazırlar. Evrişim ve Pooling katmanından gelen değerlerin tek boyutlu halini gösterir. Bundan önceki katmanlarda gerçekleştirilen işlemler matrisler şeklinde gerçekleştirilirken, bu katmanda ise işlemler tek boyutlu yapıda gerçekleştirilir (Bozkurt, 2022).


Yoğun Katman (Dense Layer): Relu, Sigmoid ve Tanh gibi aktivasyon fonksiyonlarıyla çıkışı belirler. Girdinin her bir düğümü çıkıştaki düğüme bağlıdır. Her bir katmanın girişi kendisinden önceki katmanın çıkışı ile belirlenir.

Önerilen CNN modelde kullanılan katmanlar, çıkış değerleri ve parametreler ve Şekil 3’de detaylı bir şekilde verilmiştir. Konvolüsyon ve havuzlama katmanında belirlenen katmanlara softmax ve relu katmanları eklenerek filtre sayısının artırılarak eğitim ve test görüntülerindeki sınıflandırma ve hastalık tespitinin doğru belirlenmesi sağlanmaya çalışılmıştır. Ayrıca 3 x 3’lük konvolüsyon ve 2 x 2’lik havuzlama katmanı kullanılmıştır. 3 konvolüsyon katmanı, 2 havuzlama katmanı, 1 düzleştirme, 2 yoğunluk ve 3’te bırakma katmanı kullanılmıştır.

Tablo 3’de kullanılan tüberküloz verileri için kullanılan katmanların ve parametrelerin değerleri, filtre sayıları, kullanılan ve kullanılmayan parametreler ayrıntılı olarak ele alınmıştır. 3 x 3’lük bir filtre giriş görüntüsü üzerinde gezdirilerek öznelikler tespit edilmeye çalışılır. Ağırlık ve bias değerleri sürekli güncellenerek öğrenme süreci oluşturulur. Konvolüsyon katmanı arasında havuzlama katmanı bulunmaktadır. Bu katmanın amacı görüntünün boyutunu küçülterek daha doğru bir sınıflandırma gerçekleştirebilmektedir. 2 x 2’lik maksimum havuzlama katmanı ile görüntü boyutu dörtte bir indirgenir.

Çalışmada 510 x 510 boyutundaki oluşan tüberküloz görüntüleri başlangıçta rastgele seçilen ağırlıklarla işleme onulur. Seçilen ağırlık değerleri her iterasyonda tekrar hesaplanır ve en optimum ağırlıklar tespit edilir. Bu sebeple epoch değeri çok büyük ya da çok küçük seçilmemelidir. Bu çalışmada epoch değeri 50 seçilmiştir ve her 50 epoch için 10 iterasyon belirlenmiştir. Modelin uygun yerde durdurulması için için batch size değeri belirlenir. Katman sayısı olarak da 6 belirlenmiştir. Batch size ile ağırlıklar hesaplanır ve en uygun ağırlıklar için optimize edilir. Konvolüsyon katmanında 256,128 ve 64’lük 3 x 3’lük katmanlar kullanılır. Konvolüsyon katmanında yapılan işlemlerden sonra kullanılan Relu aktivasyon fonksiyonu girilen pozitif herhangi bir a değeri için a değerini alırken, negatif değerler için ise 0 değerini alan doğrusal olmayan bir fonksiyondur. Havuzlama katmanında ise 2 x 2’lik maksimum değerler ele alınır. Düzleştirme katmanında bu iki katman sonucu elde edilen matris şeklindeki verileri tek boyutta göstererek tam bağlantılı katmana görüntüleri hazırlar. En son katmanda ise softmax aktivasyon fonksiyonu genelde kullanılır. Bu aktivasyon fonksiyonu çoklu sınıflandırma içeren problemlerinde 0-1 arasında veriler üretir.

Önerilen CNN modelinde kullanılan parametre değerleri Tablo 3’ de gösterilmiştir. 50 epoch döngüsü için 100 batch size, konvolüsyon katmanı için 3 x 3 filtreler, havuzlama katmanı için 2 x 2 filtreler, aktivasyon fonksiyonu olarak relu ve softmax kullanılmıştır. Bu çalışmada öğrenme katsayısını 0,01 alırken, optimizier olarak ise adam algoritması seçilmiştir.



Şekil 3. Önerilen CNN modeli

Tablo 4’te CNN için önerilen modelin parametre değerleri gösterilmiştir. Derin öğrenme modellerinde ince ayar (fine tuning) yapılarak hiper parametre seçimini en uygun şekilde gerçekleştirmek için Adagrad, Stokastik Gradyan İniş (Stochastic Gradient Descent – SGD), Momentum, RMSProp, Adadelta ve Adam optimizasyon algoritmaları kullanılmaktadır. Çalışmamızda bu optimizasyon algortimalarının hepsini hiper parametre seçimi için kullanılmıştır. Ancak “adam” gerek hız gerekse performans açısından diğerlerine oranla daha başarılı sonuçlar vermiştir. Önerilen tüm ağ modellerinde hiper parametreler “adam” ile eğitilmiştir. Başlangıçta öğrenme oranı 0,01 seçilmiştir. Ayrıca tüm ağlar için ağırlık kaybını azaltmak için önceden eğitilen ağırlıklar kullanılmıştır. Bırakma katmanı için 0,5 eşik değeri seçilerek parametre değerleri belirlenmiştir. Hata oranının geri yayılımı sebebiyle çıkış nöronlarında hata en aza indirginmiştir. Çünkü bu çalışmada diğer optimizasyon algoritmalarına göre gerek performans gerekse hız olarak “adam” daha avantajlıdır. Ayrıca “adam” Rmsprop ve momentum

yöntemlerinin olumlu taraflarının birleştirilmesi ile önerildiği için diğerlerine oranla daha başarılı şekilde hiper parametrelere ince ayar sağlayabilir.

Tablo 3. CNN modelinin değerleri

Parametreler	Değer
Konvolüsyon1	510,510,30
Havuzlama1	255,255,30
Konvolüsyon2	253,253,40
Havuzlama2	126,126,40
Konvolüsyon3	124,124,50
Havuzlama3	62,62,50
Düzleştirme1	192200
Yoğunluk1	50
Bırakma1	50
Yoğunluk2	30
Bırakma2	30
Yoğunluk3	2

Tablo 4. Önerilen CNN modelin parametreleri

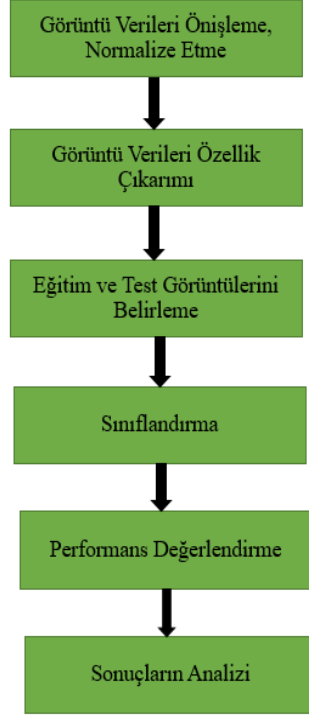
Parametreler	Değer
Epoch Sayısı	50
Filtre Boyutu (konvolüsyon)	3x3
Filtre Boyutu (havuzlama)	2x2
Aktivasyon Fonksiyonu	relu, relu, tan, relu, softmax
Loss Fonksiyonu	categorical_crossentropy
Optimizasyon	adam, SGD
Katman Sayısı	5

3.2. Transfer Öğrenme Modelleri

VGGNet Oxford Üniversitesi Visual Geometry Group (VGG) tarafından araştırılmış bir CNN mimaridir. Bu derin öğrenme modelinde girdi olarak verilen görüntüler 224 x 224 x 3 boyutundadır. 3 x 3 filtreler kullanılır ve 11 ile 19 arasında katman değerleri alabilir. 19 katman sayısını göstermektedir. Bu çalışmada başta VGG19 olmak üzere LeNet, AlexNet, DenseNet, ResNet50, Inception-V3 ve EfficientNet gibi transfer öğrenme modelleri kullanılmıştır. Bu transfer öğrenme modellerinin başarısı k=5 ile k=10 çaprazlama değerine ve farklı eğitim, test ve doğrulama örneklerine göre karşılaştırılmıştır. VGG19 modelinin yapısı Tablo 5’ de gösterilmektedir. VGG19 modelinde 16 konvolüsyon, 3 tam bağlantılı katman, 5 havuzlama katmanı ve 1 softmax katmanı içerir (İbrahim ve ark., 2021).

Tablo 5. VGG19 yapısı

Katman	Değer
2 konvolüsyon katmanı	3x3,64
2 konvolüsyon katmanı	3x3,128
4 konvolüsyon katmanı	3x3,256
4 konvolüsyon katmanı	3x3,512
4 konvolüsyon katmanı	3x3,512
havuzlama katmanı	2x2
tam bağlantılı katman	4096
tam bağlantılı katman	4096
tam bağlantılı katman	4096
softmax	-



Şekil 4. Önerilen transfer öğrenme modellerinin iş akış şeması

Bazı yaygın derin öğrenme modellerinden aşağıda kısaca bahsedilmiştir:

LeNet: Bu ağ, konvolüsyon ağının ilk başarılı uygulaması olarak kabul edilir. 1990'lı yıllarda geliştirilmiş ve posta kodları, basit basamaklar vb. okumak için kullanılmıştır.

AlexNet: Bu ağ, 2012 yılında ImageNet ILSVRC yarışmasında sunulmuştur. Diğer ağlara göre oldukça başarılıdır.

VGGNet: Bu ağ yapısı, sinir ağlarında derinlik kavramının ne kadar önemli olduğu belirtilir. 16 ya da 19 adet evrişimli katman içerir.

ResNet50: ImageNet veri kümesi üzerinde eğitilen 50 katmanlı bir ağdır.


Inception-V3: Çok sayıda konvolüsyonel ve maksimum havuzlama adımlarından oluşan bir nöral ağ modelidir.

EfficientNet: Modeli küçültmeye çalışan bir grup konvolüsyon sinir ağı modelidir. Derinlik, çözünürlük ve genişlik açısından ölçekleme yapar.

4. Bulgular

4.1. Veri Seti

Çalışmamızda kullanılan veri seti kaggle üzerinden (<https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset>) alınmıştır. Bu veri seti göğüs röntgeni verilerinden Katar ve Dhaka Üniversitesi tarafından Bangladeş'te yaşayan bir grup doktor ile Malezya'dan Hamad Medical Corporation işbirliği ile oluşturulmuştur. Toplamda sağlıklı ve hasta olmak üzere iki sınıflı 700 TB görüntüden oluşmaktadır. Çalışmamızda verilerin eğitimi için 700 görüntü kullanılırken, test işlemi için ise 300 görüntü kullanılmıştır. Bu veri setinden örnek görüntüler Şekil 5'de gösterilmiştir.



Şekil 5. Kullanılan veri seti

Bu çalışmada tüberküloz görüntüleri Python programlama dili ile yapay sinir ağları ve evrimsel sinir ağları ile eğitilmiştir ve test görüntülerinin doğruluğu farklı değerlendirme kriterleri ile hesaplanmıştır. Ayrıca çalışma sonuçları karşılaştırmalı olarak gösterilmiştir. Kullanılan görüntü verileri ilk aşamada çeşitli ön işleme adımlarından geçirilmiştir ve çalışmada daha doğru sınıflandırma sonuçları elde edilmesi için görüntüler çeşitli veri madenciliği yöntemleri ile normalize edilmiştir. Veri ön işleme adımlarında filtreleme, görüntü netleştirme, yumuşatma, gürültü azaltma, normalleştirme ve görüntüyü yeniden boyutlandırma gibi bir dizi ön işleme adımları gerçekleştirilmiştir. Gauss filtresiyle görüntünün gürültüsü giderilmiştir ve görüntü daha net hale getirilerek görüntü keskinleştirilmiştir. Böylelikle görüntü daha belirgin hale gelerek tüberkülozlu görüntüler ile sağlıklı görüntüler daha doğru biçimde birbirinden ayrılması sağlanmıştır. Ayrıca farklı veri artırımı yöntemleri ile verinin artırımı yapılarak önerilen modellerin başarısının değişip değişmediği gözlemlenmiştir. Verinin ön işlemesine ait işlemler önerilen modelin iş akışında anlatılmıştır. Veri setinde sağlıklı görüntüler daha fazla olduğundan dolayı dengesiz dağılım görülmektedir. Bu sorunu çözebilmek amacıyla SMOTE algoritması ile sentetik görüntüler oluşturulmuştur. Böylelikle az sayıda görüntüye sahip olan tüberkülozlu verilerin artırılması sağlanmıştır. Bu da sınıflandırma problemlerinde ortaya çıkan aşırı öğrenme ve ezberleme gibi

sorunların çözülmesini sağlamıştır. Ağırlıkların doğru olarak belirlenmesi için ağırlıklı atama yöntemi kullanılmıştır. Ayrıca özellik çıkarımı ve seçimi gibi yöntemler de sınıflandırma başarısını arttırmaktadır. Orijinal veri setinde 1000 görüntü verisinin 800’ü “sağlıklı” 200 ise “tüberkülozlu” veridir. Önerilen modelin sınıflandırma doğruluğu hesaplayabilmek için görüntü verileri 0.70 eğitim ile 0.30 test verisi olarak rastgele ve her sınıftan eşit olacak şekilde ayrılmıştır. Bu çalışmada veri dengelemesi için veri setindeki görüntü sayısı her iki sınıf için de (“tüberkülozlu” ve “sağlıklı”) eşit olarak artırılmış. “Tüberkülozlu” ve “sağlıklı” olarak etiketlenmiş görüntülere ait verilere ait sayılar Tablo 6’da gösterilmiştir. Döndürme, çevirme, büyütme, kontrast artırma, görüntünün boyutunu değiştirme, kırpma, bulanıklık ve gürültü ekleme gibi farklı efektler ile veri artırılarak sentetik veriler elde edilmiştir. Örneğin; ilk senaryoda 1602 “tüberkülozlu” görüntü etiketlenirken; 405 “sağlıklı” görüntü etiketlenmiştir.

Tablo 6. Tüm verilere ait etiketlenmiş görüntü sayıları

Senaryo	Tüberkülozlu	Sağlıklı	Toplam
1	1602	405	1007
2	2456	846	3302
3	3427	1278	4705
4	4023	1637	5660
5	4761	2012	6773

4.2. ANN Sonuçları

ANN modelinin uygulama sonuçları eğitim verisi ve test verisi için sırasıyla %93,17 ve %90,41 başarı elde etmiştir. Tablo 7 ve Tablo 8’de ANN modeli için sırasıyla eğitim ve test verileri için görüntülerin belirtilen değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 7. Eğitim için değerlendirme sonuçları


Eğitim Verisi	Kesinlik	Duyarlılık	F1-Puamı
0	0,8559	0,9343	0,8934
1	0,9902	0,9960	0,9931
2	0,8363	0,9382	0,8843
3	0,9544	0,9345	0,9443
4	0,8648	0,9087	0,8862
5	0,9993	0,9610	0,9798
6	0,9152	0,6885	0,7858

7	0,9495	0,9837	0,9663
8	0,9958	0,9935	0,9947
9	0,9762	0,9793	0,9778
Doğruluk	-	-	0,9318
Maksimum Ortalama	0,9338	0,9318	0,9306
Ağırlıklı Ortalama	0,9338	0,9318	0,9306

Tablo 8. Test için değerlendirme sonuçları

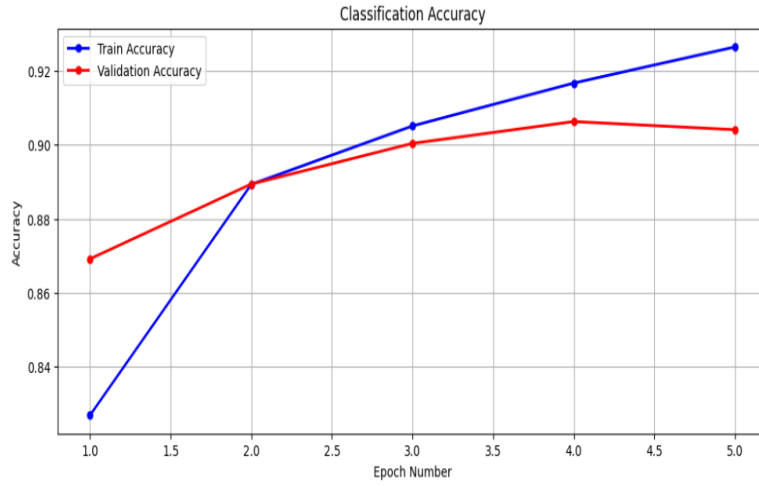
Test Verisi	Kesinlik	Duyarlılık	F1-Puanı
0	0,8338	0,8980	0,8647
1	0,9841	0,9880	0,9860
2	0,7794	0,9150	0,8418
3	0,9305	0,8970	0,9134
4	0,8186	0,8620	0,8397
5	0,9937	0,9480	0,9703
6	0,8419	0,6070	0,7054
7	0,9297	0,9790	0,9537
8	0,9820	0,9830	0,9825
9	0,9650	0,9640	0,9645
Doğruluk	-	-	0,9041
Maksimum Ortalama	0,9059	0,9041	0,9022
Ağırlıklı Ortalama	0,9059	0,9041	0,9022

Tüberküloz veri seti için çapraz entropi (cross entropy) hata değerlerinin değişimi Şekil 6' da epoch değerlerine göre gösterilmiştir. Grafikte anlaşıldığı üzere 1. epoch da hata en yüksek, 5. epoch da hata en düşük olmaktadır.




Şekil 6. Çapraz entropi hata grafiği

Ağırlıklar sürekli güncellenmekte olup, en iyi öğrenmenin kaçınıcı epoch da gerçekleştiği Şekil 7’ de gösterilmiştir.




Şekil 7. Sınıflandırma doğruluğu grafiği

Çapraz doğrulama ile yapılan tüm veri için ANN sonuçlarının (k=8 için) ortalaması ROC ve AUG eğrileri Şekil 8’de gösterilmiştir. k=8 için 85,76 başarı elde edilmiştir. k=8 seçilme nedeni ise yapılan tüm analizlerin ortalamasına bakarak önerilen modelin başarısını göstermektir. Ayrıca k=8 çapraz doğrulama için karmaşıklık matrisi Şekil 9’da verilmiştir.



Şekil 8. ANN için ROC ve AUG eğrisi (k=8 için)



Şekil 9. Karmaşıklık matrisi

Tablo 9’da beş farklı senaryoya göre ANN ile doğru olarak tespit edilen “tüberkülozlu” verilerin sayısı verilmiştir.

Tablo 9. ANN Modelinin Senaryolara göre Tahmin Edilen Örnek Sayısı


Senaryo	Doğru tahmin edilen “tüberkülozlu” olarak etiketlenen görüntü sayısı
Senaryo 1	1427
Senaryo 2	2015
Senaryo 3	2867
Senaryo 4	3764
Senaryo 5	4033

4.3. CNN Sonuçları

Önerilen CNN modelinin uygulama sonuçları eğitim verisi ve test verisi için sırasıyla %99,44 ve %98,91 başarı elde etmiştir. Tablo 10 ve Tablo 11’de CNN modeli için sırasıyla eğitim ve test verileri için görüntülerin belirtilen değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir. Tüberküloz veri seti için çapraz entropi (cross entropy) hata değerlerinin değişimi Şekil 10’ da epoch değerlerine göre gösterilmiştir. Grafikte anlaşıldığı üzere 1. epoch da hata en yüksek, 5. epoch da hata en düşük olmaktadır.

Tablo 10. Eğitim için değerlendirme sonuçları

Eğitim Verisi	Kesinlik	Duyarlılık	F1-Puanı
0	0,9930	0,9973	0,9983
1	0,9939	0,9970	0,9955
2	0,9935	0,9970	0,9952
3	0,9954	0,9977	0,9966
4	0,9910	0,9957	0,9933
5	0,9921	0,9983	0,9952
6	0,9988	0,9921	0,9954
7	0,9979	0,9808	0,9893
8	0,9940	0,9954	0,9947
9	0,9883	0,9938	0,9910
Doğruluk	-	-	0,9944
Maksimum Ortalama	0,9944	0,9945	0,9945
Ağırlıklı Ortalama	0,9945	0,9944	0,9944

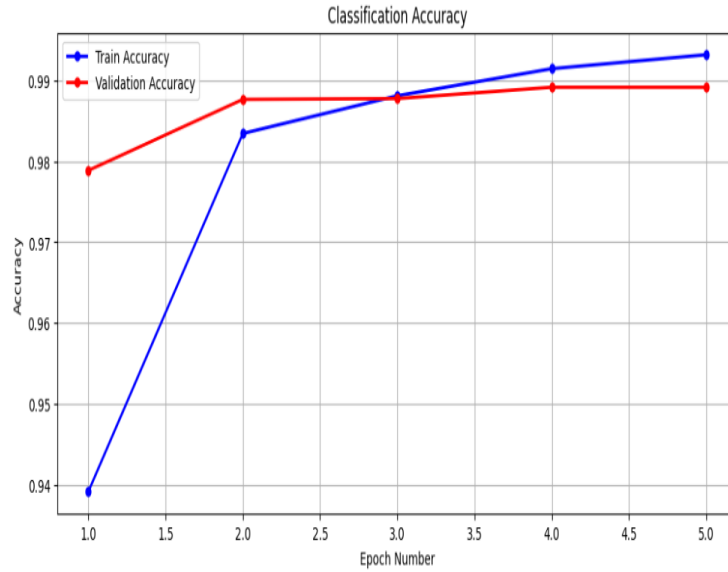


Şekil 10. Çapraz entropi hata grafiği

Tablo 11. Test için değerlendirme sonuçları


Test Verisi	Kesinlik	Duyarlılık	F1-Puanı
0	0,9969	0,9949	0,9959
1	0,9913	0,9982	0,9947
2	0,9808	0,9922	0,9865
3	0,9863	0,9960	0,9911
4	0,9809	0,9949	0,9879
5	0,9833	0,9910	0,9872
6	0,9968	0,9802	0,9884
7	0,9970	0,9708	0,9837
8	0,9877	0,9928	0,9903
9	0,9910	0,9802	0,9856
Doğruluk	-	-	0,9892
Maksimum Ortalama	0,9892	0,9891	0,9891
Ağırlıklı Ortalama	0,9893	0,9892	0,9892

Ağırlıklar sürekli güncellenmekte olup, en iyi öğrenmenin 5. epoch da gerçekleştiği Şekil 11’ de gösterilmiştir.

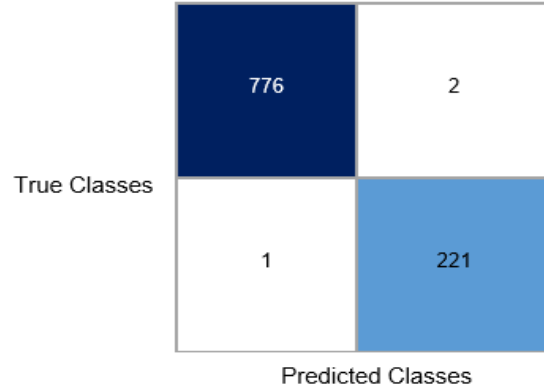


Şekil 11. Sınıflandırma doğruluğu grafiği

Çapraz doğrulama ile yapılan tüm veri için CNN sonuçlarının (k=8 için) ortalaması ROC ve AUG eğrileri Şekil 12’de gösterilmiştir. k=8 için %97,78 başarı elde edilmiştir. k=8 seçilme nedeni ise yapılan tüm analizlerin ortalamasına bakarak önerilen modelin başarısını göstermektir. Ayrıca k=8 çapraz doğrulama için karmaşıklık matrisi Şekil 13’de verilmiştir. Tablo 12’de beş farklı senaryoya göre CNN ile doğru olarak tespit edilen “tüberkülozlu” verilerin sayısı verilmiştir.



Şekil 12. CNN için ROC ve AUG eğrisi



Şekil 13. Karmaşıklık matrisi

Tablo 12. CNN Modelinin Senaryolara göre Tahmin Edilen Örnek Sayısı

Senaryo	Doğru tahmin edilen “tüberkülozlu” olarak etiketlenen görüntü sayısı
Senaryo 1	1591
Senaryo 2	2231
Senaryo 3	3029
Senaryo 4	3862
Senaryo 5	4154

Tablo 13’de farklı eğitim, test ve doğrulama örneklerine göre farklı derin öğrenme modellerinin sonuçları verilmiştir. Sonuçlar analiz edildiğinde ResNet50 ve VGG16 modellerinin diğer modellere göre daha başarılı sonuçlar verdiği gözlemlenmiştir. Tablo 14’de tüm modellerin k=5 ve k=10 çapraz doğrulama sonucu elde edilen sonuçları verilmiştir.

Tablo 13. Tüm modellerin farklı eğitim, doğrulama ve test verilerine göre doğruluk sonuçları

Metod/Doğruluk (%)	ResNet50	VGG19	Inception-V3	EfficientNet	DenseNet	LeNet	AlexNet
%60 eğitim %40 test	96,42	95,86	92,52	92,73	94,37	92,45	92,07
%70 eğitim %30 test	96,31	96,61	94,71	94,86	95,35	93,82	91,37
%60 eğitim %20 doğrulama %20 test	96,87	96,83	93,64	94,37	96,41	90,37	92,55
%70 eğitim %15 doğrulama %15 test	97,19	98,03	95,37	95,90	97,68	91,61	92,97

Tablo 14. Çapraz doğrulama sonucu elde edilen sonuçlar

Yöntem/Doğruluk (%)	k=5	k=10
ANN	88,23	84,67
CNN	96,72	96,49
ResNet50	95,64	95,06
VGG19	94,94	95,61
Inception-V3	92,40	91,64
EfficientNet	94,81	93,75

DenseNet	94,92	93,91
LeNet	93,41	92,41
AlexNet	92,12	90,37

5. Tartışma ve Sonuç

Tüberküloz, Mycobacterium tuberculosis adı verilen bakterinin neden olduğu bir enfeksiyon hastalığıdır. Tüberküloz, dünya genelinde hala önemli bir halk sağlığı sorunudur ve özellikle gelişmekte olan ülkelerde yaygın olarak görülmektedir. Solunum yoluyla bulaşan bu hastalık, özellikle akciğerleri etkileyerek ciddi semptomlara yol açabilir. Tüberkülozun belirtileri arasında uzun süreli öksürük, nefes darlığı, göğüs ağrısı, zayıflama, ateş, gece terlemeleri ve halsizlik gibi semptomlar bulunur. Hastalığın tanısı, klinik belirtilerin yanı sıra biyomedikal görüntüleme yöntemleri ve laboratuvar testleri ile konulmaktadır.

Hastalığın tespit edilmesinde röntgen, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi teknikleri bulunur. Hastalığın erken teşhisi, hastalığın tedavisi ve yayılmasının önlenmesi açısından büyük önem taşımaktadır. Derin öğrenme yöntemlerinin biyomedikal görüntülerin tüberküloz hastalığının sınıflandırılmasında kullanılması, tanı sürecini hızlandırabilir, doğruluğu artırabilir ve tedaviye daha etkin bir şekilde rehberlik edebilir. Bu tezde, tüberküloz hastalığının derin öğrenme ile sınıflandırılması konusunda önemli bir adım olmayı hedeflemektedir. Önerdiğimiz model farklı akciğer hastalıklarının (TB, COVID-19 ve grip gibi) erken teşhisine yönelik bir çalışma ile bu alanda çalışan radyologlara ve doktorlara yardımcı olabilir.

Bu çalışmada, doktorların göğüs röntgeni ile tüberküloz hastalığını doğru ve hızlı olarak teşhis etmesine yardımcı olmak amacıyla bir yöntem geliştirilmiştir. Önerilen CNN modeliyle tüberkülozlu ve sağlam olarak etiketlenen test görüntüleri tespit edilmiştir. Farklı ve derin bir ağ yapısı ile hastalığın otomatik olarak tespiti sağlanmıştır. Manuel olarak ortaya çıkabilecek yanlış anı ve teşhisler önlenmeye çalışılmıştır.

Çalışmada ayrıca ANN, önerilen CNN ve önerilen hibrit modelin performans ölçümleri farklı değerlendirme ölçütleri (hassaslık, duyarlık, kesinlik, F1-puanı) ile hesaplanmıştır ve tüm modellerin sonuçları karşılaştırmalı olarak sunulmuştur. Bu çalışmada önerilen modellerin ağ yapısı, parametre değerleri, kullanılan katmanlar, doğrulama verileri için elde edilen karmaşıklık matrisleri, doğruluk ve kayıp grafikleri ayrıntılı olarak gösterilmiştir. Çalışmamızda literatürde kullanılan sinir ağlarından farklı bir ağ yapısı kullanılarak başarı oranı arttırılmıştır. Tablo 15’de bizim çalışmamız diğer çalışmalarla karşılaştırmalı olarak sunulmuştur. Önerilen CNN modeliyle %98,91 başarı elde edilmiştir. Ayrıca ön eğitilmiş modellerle de önerilen modellerin başarıları karşılaştırılmıştır. Çalışmada kullanılan BT görüntüleri 5 farklı senaryo için etiketlenmiş ve tüm senaryoların başarı sonuçlarının ortalama değerleri alınmıştır. Ayrıca çalışmada kullanılan tüm derin öğrenme modellerinin doğruluk sonuçları karşılaştırılmıştır.

Tablo 15. Literatürdeki çalışmaların karşılaştırılması

Çalışma	Metot	Doğruluk (%)
Hrizi ve ark., 2023	CNN	97,06
Hrizi ve Attia, 2023	SVM,	95,10
	Random Forest,	98,60
	Xgboost,	95,10
	Karar Ağaçları	95,60
Hrizi ve Gasmi, 2023	Genetik Algoritma	97,00
Gasmi ve ark., 2024	Deep Belief Network (DBN)	97,20
Iqbal ve Usman, 2022	TBXNet	95,10
Iqbal ve ark., 2023	CNN-based hybrid model	97,70
Abubakar ve ark., 2024	DNN	98,00
Fatihah ve ark., 2024	SVM	80,00
Önerdiğimiz model	CNN	98,91

CNN modelinde ağıın eğitimi, geri yayılım (backpropagation) algoritmasına dayanır. Geri yayılım, ağıın çıktılarının gerçek etiketlerden ne kadar uzak olduğunu ölçen bir kayıp fonksiyonu kullanarak hata hesaplar. Bu hata daha sonra ağıın tüm katmanlarına geriye doğru iletilir ve ağırlıkların güncellenmesiyle birlikte öğrenme süreci gerçekleştirilir. Bu çalışmada çok hızlı ve doğru sonuçlar ürettiği için “adam” optimizasyon algoritması kullanılmıştır. “Adam” optimizasyon algoritması momentum ve RmsProb algoritmalarını birleştirip kullandığı için diğer optimizasyon algoritmaların dezavantajlı yönlerini de azaltmaktadır. Önerilen modellerin başarısı yeterli görüntü veri kümesi üzerinde gerçekleştirilmesine rağmen daha büyük görüntülerde ve daha büyük veri kümelerinde önerilen modellerin başarısına bakılması gerekmektedir. İleriki çalışmalarda büyük veri kümeleri üzerindeki başarısı ölçülecektir. Gelecekte çalışmada kullanılan derin öğrenme modellerine ek olarak hibrit yöntemler geliştirilecektir ve hibrit modellerin başarısı çok sınıflı problemler için ölçülecektir. Ayrıca farklı hastalık türleri ve gerçek tıp görüntüleri üzerinde önerilen modeller gerçekleştirilecektir.

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir çıkar çatışması olmadığını beyan eder.

Araştırmacıların Katkı Oranı Beyan Özeti

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan ederler. Çalışma Mehmet BABALIK’ın yüksek lisans tezinden üretilmiştir.

Kaynakça

- Abubakar MZ., Mustafa K., Sani, KJ. Automated tuberculosis classification with chest x-rays using deep neural networks-case study: Nigerian Public Health. *Turkish Journal of Science and Technology* 2024; 19(1): 55-64.
- Al-Shayea QK. Artificial neural networks in medical diagnosis. *International Journal of Computer Science Issues* 2011; 8(2): 150-154.
- Ammar LB., Gasmi K., Ltaifa IB. ViT-TB: Ensemble learning based ViT Model for tuberculosis recognition. *Cybernetics and Systems* 2022; 1-20.
- Angeli C. Diagnostic expert systems: From expert's knowledge to real-time systems. *Advanced knowledge-based systems: Model, applications & Research* 2010; 1: 50-73.
- Asakawa T., Tsuneda R., Shimizu K., Aono M. Cavens detection and cavens report in tuberculosis: lesion detection based on image using YOLO-V3 and median based multi-label multi-class classification using SRGAN. In *CLEF2022 Working Notes CEUR Workshop Proceedings 2022*, Bologna, Italy.
- Ayas S., Ekinçi M. Random forest-based tuberculosis bacteria classification in images of ZN-stained sputum smear samples. *Signal, Image and Video Processing* 2014; 8: 49-61.
- Bisht R., Mittal K., Prasad G. Evaluation of CNN models for accurate classification of COVID-19, pneumonia, tuberculosis in chest X-ray Images. In *2023 3rd Asian Conference on Innovation in Technology (ASIANCON) 2023*, IEEE.
- Bozkurt F. Skin lesion classification on dermatoscopic images using effective data augmentation and pre-trained deep learning approach. *Multimedia Tools and Applications* 2023; 2(12): 18985-19003.
- Bozkurt F. Derin öğrenme tekniklerini kullanarak akciğer X-ray görüntülerinden COVID-19 tespiti. *Avrupa Bilim ve Teknoloji Dergisi* 2021; 24: 149-156.
- Bozkurt F. A deep and handcrafted features-based framework for diagnosis of COVID-19 from chest x-ray images. *Concurrency and Computation: Practice and Experience* 2022; 34(5): 1-19.
- Bozkurt F., Yağanoğlu M. Derin evrişimli sinir ağları kullanarak akciğer X-Ray görüntülerinden COVID-19 tespiti. *Veri Bilimi* 2021; 4(2): 1-8.
- Breve, FA.. COVID-19 detection on Chest X-ray images: A comparison of CNN architectures and ensembles. *Expert systems with applications* 2022; 204: 117549.
- Cao K., Zhang J., Huang M., Deng T. X-ray classification of tuberculosis based on convolutional networks. In *2021 IEEE International Conference on Artificial Intelligence and Industrial Design (AIID) 2021*, IEEE.
- Elveren E., Yumuşak N. Tuberculosis disease diagnosis using artificial neural network trained with genetic algorithm. *Journal of Medical Systems* 2011; 35: 329-332.

- Er O., Tanrikulu AÇ., Temurtas F. Tuberculosis disease diagnosis using artificial neural networks. *Journal of Medical Systems* 2010; 34(3): 299-302.
- Fatihah HA., Kurniawan I. Prediction of tuberculosis on HIV patients based on gene expression data using grey wolf optimization-support vector machine. In *2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems (ICETSYS) 2024*, IEEE.
- Gasmi K., Kharrat A., Ammar LB., Ltaifa IB., Krichen M., Hrizi O. Classification of MRI brain tumors based on registration preprocessing and deep belief networks. *AIMS Mathematics* 2024; 9(2): 4604-4631.
- Gichuhi HW. A machine learning model to explore individual risk factors for tuberculosis treatment refill non-adherence in Mukono District. Makerere Üniversitesi, Yayınlanmış Doktora Tezi 2023.
- Gruson D. Data science, artificial intelligence, and machine learning: opportunities for laboratory medicine and the value of positive regulation. *Clinical Biochemistry* 2019; 69: 1-7.
- Hafeez U., Umer M., Hameed A., Mustafa H., Sohaib A., Nappi M., Madni HA. A CNN based coronavirus disease prediction system for chest X-rays. *Journal of Ambient Intelligence and Humanized Computing* 2023; 14(10): 13179-13193.
- Hrizi D., Tbarki K., Attia M., Elasmı S. Lung cancer detection and nodule type classification using image processing and machine learning. In *2023 International Wireless Communications and Mobile Computing (IWCMC) 2023*, IEEE.
- Hrizi D., Tbarki K., Elasmı S. Lung cancer detection and classification using CNN and image segmentation. In *2023 IEEE Tenth International Conference on Communications and Networking (ComNet) 2023*, IEEE.
- Hrizi O., Gasmi K., Ltaifa I., Alshammari H., Karamti H., Krichen M., Mahmood MA. Tuberculosis disease diagnosis based on an optimized machine learning model. *Journal of Healthcare Engineering* 2022; 2022:1-13.
- Hrizi O., Gasmi K., Ltaifa IB., Alshammari H., Karamti H., Krichen M., Mahmood MA. Tuberculosis disease diagnosis based on an optimized machine learning model. *Journal of Healthcare Engineering*, 2022.
- Iqbal A., Usman M. An efficient deep learning-based framework for tuberculosis detection using chest X-ray images. *Tuberculosis* 2022; 136, 102234.
- Iqbal A., Usman M., Ahmed Z. Tuberculosis chest X-ray detection using CNN-based hybrid segmentation and classification approach. *Biomedical Signal Processing and Control* 2023; 84: 104667.
- Iqbal A., Usman M., Ahmed Z. Tuberculosis chest X-ray detection using CNN-based hybrid segmentation and classification approach. *Biomedical Signal Processing and Control* 2023; 84, 104667.

- Kant S., Srivastava MM. Towards automated tuberculosis detection using deep learning. In 2018 IEEE Symposium Series on Computational Intelligence (SSCI) 18- 21 Kasım 2018 Bangalore, Hindistan.
- Karaddi SH., Sharma, LD. Automated multi-class classification of lung diseases from CXR-images using pre-trained convolutional neural networks. *Expert Systems with Applications* 2023; 211: 118650.
- Khatri A., Jain R., Vashista H., Mittal N., Ranjan P. Pneumonia identification in chest x-ray images using EMD. In *Internet of Things—Applications and Future*; Springer Science and Business Media LLC 2020, Singapore.
- Lakhani P., Sundaram B. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology* 2017; 284(2): 574-582.
- Lestari V., Mawengkang H., Situmorang Z. Artificial Neural Network Backpropagation Method to Predict Tuberculosis Cases. *Sinkron jurnal dan penelitian teknik informatika* 2023; 8(1): 35-47.
- Li Z., Xu X., Cao X., Liu W., Zhang Y., Chen D., Dai H. Integrated CNN and federated learning for COVID-19 detection on chest X-ray images. *IEEE/ACM Transactions on Computational Biology and Bioinformatics* 2022.
- Liu C., Cao Y., Alcantara M., Liu B., Brunette M., Peinado J., Curioso W. TX-CNN: Detecting tuberculosis in chest X-ray images using convolutional neural network. In 2017 IEEE international conference on image processing (ICIP) 2017, IEEE.
- Lubis AR., Prayudani S., Fatmi Y.,Lase YY. Detection of HOG features on tuberculosis X-Ray results using SVM and KNN. In 2021 2nd International Conference on Innovative and Creative Information Technology (ICITech) 1-3 September 2021.
- Malik H., Anees T., Din M., Naeem A. CDC_Net: Multi-classification convolutional neural network model for detection of COVID-19, pneumothorax, pneumonia, lung Cancer, and tuberculosis using chest X-rays. *Multimedia Tools and Applications* 2023; 82(9): 13855-13880.
- Nafisah SI., Muhammad G. Tuberculosis detection in chest radiograph using convolutional neural network architecture and explainable artificial intelligence. *Neural Computing and Applications* 2022; 1-21.
- Rahman T., Akinbi A., Chowdhury ME., Rashid TA., Şengür A., Khandakar A., Ismael A. COV-ECGNET: COVID-19 detection using ECG trace images with deep convolutional neural network. *Health Information Science and Systems* 2022; 10(1): 1-10.
- Rahman T., Khandakar A., Kadir MA., Islam KR., Islam KF., Mazhar R. Reliable tuberculosis detection using chest X-ray with deep learning, segmentation and visualization. *IEEE Access* 2020; 8: 191586-191601.
- Shakya T., Jeyavathana RB., Kumar PK. Improved accuracy in automatic detection of tuberculosis disease from lung ct images using support vector machine classifier over K-nearest neighbours classifier. In 2022 International Conference on Cyber Resilience (ICCR) 1-3 October 2022.

- Singh M., Pujar GV., Kumar SA., Bhagyalalitha M., Akshatha HS., Abuhaija B., Gandomi, AH. Evolution of machine learning in tuberculosis diagnosis: a review of deep learning-based medical applications. *Electronics* 2022; 11(17): 2634.
- Sun M., Song Z., Jiang X., Pan J., Pang Y. Learning pooling for convolutional neural network. *Neurocomputing* 2017; 224: 96-104.
- Pannu A. Artificial intelligence and its application in different areas. *Artificial Intelligence* 2015; 4(10): 79-84.
- Pardue H., Schnipelsky P. Use of artificial intelligence in analytical systems for the clinical laboratory. *Clinica Chimica Acta* 1994; 231(2): S1-S34.
- Venkataramana L., Prasad DV., Saraswathi S., Mithumary CM., Karthikeyan R., Monika N. Classification of COVID-19 from tuberculosis and pneumonia using deep learning techniques. *Medical & Biological Engineering & Computing* 2022; 60(9): 2681-2691.
- Woolever DR. The impact of a patient safety program on medical error reporting. *Journal of Medical Regulation* 2005; 91(3): 16-21.