

DERİN ÖĞRENME İLE AKCİĞER X-ray GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ

Hatice DOYMAZ *
Figen ERTAŞ **

Alınma: 25.03.2025; düzeltme: 17.11.2025; kabul: 08.01.2026

Öz: Derin Öğrenme ile hastalık teşhisi son dönemlerde araştırmacıların üstünde yoğun şekilde çalıştıkları bir konu olup, yöntemleri pek çok sağlık alanında başarıyla uygulanmaktadır. Günümüzdeki birçok araştırmadan görüleceği üzere Derin Öğrenmenin tıp alanında kullanımı, 2019 yılının sonlarında ortaya çıkan ve pandemiye yol açan COVID-19 hastalığı ile daha da önem kazanmıştır. Bu çalışmada ResNet50, Inceptionv3, VGG16, AlexNet ve ayrıca 5 aşamalı evrişim ile 2 adet tam bağlantılı katman halinde tasarlanan 3,6 milyon parametrelili bir model kullanılmıştır. İki ayrı veri setinden, görüntüler rastgele şekilde, her bir sınıftan 500 adet olacak şekilde, seçilip toplamda 2500 görüntü verisi kullanılarak, Covid-19 (C), Bakteriyel Zatürre (BZ), Viral Zatürre (VZ), Akciğer Opaklığı (AO) ve Normal (N) olmak üzere, 5 sınıf içeren bir veri seti oluşturulmuştur. ResNet50 modeli ile %95,73 doğruluk, 0,9574 F1 skor ve 0,99672 AUC değeri, Inceptionv3 modeli ile %92,53 doğruluk, 0,9251 F1 skor ve 0,99264 AUC değeri, VGG16 modeli ile %97,33 doğruluk, 0,9734 F1 skor ve 0,9978 AUC değeri, AlexNet modeli ile %94,67 doğruluk, 0,9487 F1 skor ve 0,99653 AUC değeri, ve son olarak tasarlanan model ile %95,22 doğruluk, 0,9521 F1 skor ve 0,99868 AUC değeri elde edilmiştir.

Anahtar Kelimeler: Akciğer X-ray görüntüleri, Covid-19, zatürre, derin öğrenme

Disease identification from chest X-ray images using deep learning

Abstract: Disease identification using deep learning has been an intensive area of research over the last years, and the models of which have been successfully employed in medical applications. Being of evidence from the studies conducted in recent years, the use of deep learning in medical sciences has gained more attention due to Covid-19 pandemic emerging in late 2019. In this work, ResNet50, Inceptionv3, VGG16, AlexNet, and a model designed as five-stages deep convolutional neural network cascaded with two fully connected layers, having 3.6 million parameters in total, has been used. A data set of 2500 images has been set up to consist of five classes labelled as Covid-19 (C), Bacterial Pneumonia (BZ), Viral Pneumonia (VZ), Lung Opacity (AO) and Normal (N), each of which has 500 entries randomly drawn from two different image data base. With the ResNet50 model, 95.73% accuracy, 0.9574 F1 score and 0.99672 AUC, with the Inceptionv3 model, 92.53% accuracy, 0.9251 F1 score and 0.99264 AUC, with the VGG16 model, 97.33% accuracy, 0.9734 F1 score and 0.9978 AUC, with the AlexNet model, 94.67% accuracy, 0.9487 F1 score and 0.99653 AUC, and finally with the designed model, 95.22% accuracy, 0.9521 F1 score and 0.99868 AUC value have been obtained.

Keywords: Chest X-ray images, Covid-19, pneumonia, deep learning

1. GİRİŞ

17 Kasım 2019 tarihinde Çin'in Wuhan eyaletinde, üst solunum yolu ve akciğer enfeksiyonu olarak ortaya çıkan COVID-19, hızla yayılarak tüm dünyayı etkisi altına alarak küresel bir

* Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği ABD, 16059, Bursa

** Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 16059, Bursa

İletişim Yazarı: Hatice Doymaz (502305020@ogr.uludag.edu.tr)

boyuta ulaştı ve 11 Mart 2020'de Dünya Sağlık Örgütü (DSÖ) tarafından küresel salgın ilan edildi. 12 Nisan 2024 tarihi itibarıyla dünyada 704.753.890 onaylanmış vaka, 675.619.811 iyileşen varken virüs nedeniyle 7.010.681 hastanın öldüğü bildirildi (Wikipedia, 2024). Her ülke bu hastalıkla mücadelede farklı yöntemler izlemiş olsalar da geçerli ve tüm dünya tarafınca ortak kabul edilen tek yaklaşım hastalığın hızlı tespiti ve izolasyon olmuştur. Dolayısıyla, hastalıkların doğru olarak tespit edilmesi büyük önem arz etmiştir. COVID-19 hastalığının teşhisinde RT-PCR, bilgisayarlı tomografi (BT) ve akciğer X-ray görüntüleri en çok kullanılan yöntemler olmuştur. RT-PCR testinin hastalığın erken evrelerinde yüksek oranda yanlış negatif sonuç vermesi, testlerin sonuç verme süresinin uzun olması, hasta ile sağlık çalışanının yakın teması gerektirip elle örnek alınarak yapılması ve kitlerin tek kullanımlık olması nedeniyle her hasta için yeni bir kit gerektirmesi gibi dezavantajlarından dolayı (WHO, 2021; Wang ve diğ., 2020; Bouchareb ve diğ., 2021), Ekim 2020'de DSÖ tarafından göğüs görüntüleme yöntemlerinin, virüsten etkilenen ve iyileşen kişilerin klinik belirtilerinin tespiti için etkili bir yöntem olduğu önerilmiştir (WHO, 2020). Ancak X-ray görüntülerinin uzman radyologlarca yaklaşık 5-6 dakikalık çalışma ile yapılabilmesi ve COVID-19 ile çeşitli viral ve bakteriyel zatürre görüntülerinin benzer özellikler içermesinden dolayı (Bozkurt, 2021) hatalı tespit yapılabileceğinden, bu görüntülerin derin öğrenme modelleri kullanılarak daha doğru ve hızlı teşhis edilebileceği kanısına varılmıştır.

Derin öğrenme, insan beyninin karmaşık öğrenme ve karar verme gücünü taklit etmek için derin sinir ağları denilen çok katmanlı sinir ağlarını kullanan bir çeşit makine öğrenimidir. Bu ağların "derinliği", derin öğrenmeye adını ve karmaşık sorunları çözme yetisini veren, giriş ve çıkış arasındaki katmanların sayısıdır. Derin öğrenmeyi klasik yöntemlere göre daha avantajlı kılan ise öznetelik çıkarma aşamasının olmamasıdır. Derin öğrenmede ağ, ham girdiyi alır ve istenen çıkışa eşler. Öznetelikler insan müdahalesine gerek kalmadan ağ tarafından verilerden otomatik olarak öğrenilir. Günümüzde örüntü tanıma ve görüntü sınıflandırma işlemleri gibi alanlarda da kullanılmaya başlanan derin öğrenme, hali hazırda bilgisayarla görme, ses tanıma ve doğal dil işleme alanlarında da başarıyla kullanılmaktadır (Singh ve diğ., 2020).

Özellikle pandemi süresince ve sonrasında, yapay zeka yöntemleri arasında en yaygın olarak kullanılan derin öğrenme yöntemi, X-ray, MRI ve BT gibi tıbbi görüntüleme yöntemlerinden elde edilen görüntülerin analizinde kullanımı hızla artış göstermiştir ve tıbbi görüntüler ile çeşitli akciğer hastalıklarının, yüksek doğrulukla, teşhis edilmesini kolaylaştırmıştır (Ardila ve diğ., 2019; Suzuki, 2017; Coudray ve diğ., 2018). Ayrıca literatürden de görüleceği üzere, 2017'de cilt lezyonlarını sınıflandırma problemi için dermatolog düzeyinde performans göstermiş (Esteva ve diğ., 2017), 2019'da ise akciğer kanseri taraması için çok etkileyici sonuçlar elde etmiştir (Ardila ve diğ., 2019). Bilgisayar destekli teşhis sistemleri, doktorların gözlemsel hatalarını azaltmak ve teşhis doğruluğunu yükseltmek amaçlı olup, günümüz tıp endüstrisinde önemli bir rol oynayacak kadar ilerleme kaydetmiştir (Arun ve diğ., 2023).

Bu çalışmada, göğüs röntgeni görüntülerinden akciğer hastalıklarını sınıflandırmak için, literatürde sıklıkla adı geçen iki farklı akciğer veri setinden seçilen görüntülerden oluşturulan ve Covid-19, Bakteriyel Zatürre, Viral Zatürre, Akciğer Opaklığı ve Normal olmak üzere 5 sınıfa temsil eden karma bir veri seti kullanılarak, basit bir evrimsel sinir ağı modeli tasarlanmıştır. Tasarlanan modelin söz konusu 5 hastalık sınıflandırmasındaki başarısı, özellikle görüntülerden nesne tanıma konusunda son zamanlarda popüler olan ResNet50, Inceptionv3, VGG16 ve AlexNet modellerinin performanslarıyla karşılaştırılmıştır. Önerilen ESA mimarisinin başarımı, karşılaştırılan mimarilerin ikisinden daha iyi, diğer ikisinden ise daha kötü olarak bulunmuş ancak hem hesaplama verimliliği, daha kısa bir öğrenme süresi ve daha küçük miktarda bellek ihtiyacı avantajlarına sahip olduğu görülmüştür.

2. İLGİLİ ÇALIŞMALAR

Literatürde, X-ray ya da BT görüntüleri üzerinden COVID-19 tespitinde derin öğrenme modelleri kullanan birçok çalışma bulunmaktadır. Çalışmalar, kullandıkları veri setleri, görüntü türü (X-ray ya da BT) ve derin öğrenme modelleri olarak farklılıklar göstermektedir. Tablo 1’de, bu kısımda atıfta bulunulan çalışmalara ait, kullanılan veri seti, veri tipi, sınıf sayısı ve hastalık adı, uygulanan derin öğrenme modeli ve çalışmanın ulaştığı doğruluk değerleri verilmiştir.

Tablo 1. Önerilen yöntemin performansının, literatürdeki benzer çalışmalar ile karşılaştırılması


Çalışma	Veri seti	Veri tipi	Sınıf sayısı	Yöntem	Doğruluk (%)
Brunese ve diğ. (2020)	Farklı veri setlerinden	X-ray	2 C/N	VGG16	97,00
Ismael ve Şengür (2021)	COVID-19	X-ray	2 C/N	ResNet50+SVM	94,70
Demir ve Yılmaz (2021)	COVID-19 Radiography Database	X-ray	2 C/N	VGG16	9700
Nayak ve diğ. (2021)	COVID-19 image data collection	X-ray	2 C/N	AlexNet Inception v3 ResNet50	97,50 92,50 97,50
Loey ve diğ. (2020)	Farklı veri setlerinden	X-ray	3 C/N/BZ	AlexNet GoogleNet ResNet18	85,19 81,48 81,48
Ibrahim ve diğ. (2021)	4 farklı veri setinden	X-ray	3 C/N/BZ	AlexNet	94,00
Ullah ve diğ. (2023)	COVIDx dataset	X-ray	3 C/N/Z	DAM-Net	97,22
Sevli (2022)	COVID-19 Radiography Database	X-ray	3 C/N/VZ	VGG16 AlexNet ResNet18	98,31 97,03 99,25
Condaragiu ve Ciocoiu (2021)	COVID-19 Radiography Database	X-ray	4 C/N/Z/AO	ResNet50 VGG16 Inception v3	96,70 95,80 96,20
Loey ve diğ. (2020)	Farklı veri setlerinden	X-ray	4 C/N/BZ/VZ	AlexNet GoogleNet ResNet18	66,67 80,56 69,46
Afshar ve diğ. (2020)	COVIDx dataset	X-ray	4 C/N/BZ/VZ	Capsule Networks	95,70
Khan ve diğ. (2020)	2 farklı veri seti	X-ray	4 C/N/BZ/VZ	Coronet	89,60
Önerilen Yöntem	2 farklı veri seti	X-ray	5 C/N/BZ/VZ/AO	ResNet50 Inception v3 VGG16 AlexNet Özgün Tasarım	95,73 92,53 97,33 94,67 94,67

Pandemi süresince yapılan çalışmalar daha çok ikili sınıflandırma olup, COVID-19 pozitif ve COVID-19 negatif ayrımı üzerinde yoğunlaşmıştır (Brunese ve diğ., 2020; Ismael ve Şengür , 2021; Demir ve Yılmaz, 2021; Nayak ve diğ., 2021). Yine aynı süreçte, COVID-19/Zatürre/Normal (sağlıklı) olmak üzere üçlü sınıflandırmalar da sıklıkla çalışılmıştır (Loey ve diğ., 2020; Ibrahim ve diğ., 2021; Ullah ve diğ., 2023; Sevli, 2022). İkili ya da üçlü sınıf haricinde sayıca çok olmasa da, 4'lü olarak COVID-19/ Normal/Viral Zatürre/Bakteriyel Zatürre ayrımı üzerinde yapılmış çalışmalarda bulunmaktadır (Condaragi ve Ciocoiu, 2021; Loey ve diğ., 2020; Afshar ve diğ., 2020; Khan ve diğ., 2020).

Tablo 1'de değerlendirilen çalışmaların doğruluk değerleri % 80,56 ile % 99,25 arasında değişmektedir. Bu çalışmadaki 5 sınıflı özgün tasarım modelinin doğruluk değeri %94,67 olarak bulunmuştur. Ancak, bu başarımın tabloda verilen modellerinkiyle karşılaştırılması sınıf sayılarının beşten küçük olması sebebiyle anlamlı olmayacaktır.

3. EVRİŞİMSEL SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORKS - CNN)

ESA'lar, yapay sinir ağlarının (YSA) özel bir varyantı olup, görüntü işleme alanında yaygın olarak kullanılan bir derin öğrenme yapısıdır. ESA'lar, klasik YSA yapılarına benzer şekilde nöronlar barındırır ve öğrenme sürecinde ağırlıklar ve sapma değerlerini kullanır. Her nöron, gelen girdileri alır, birleştirir ve genellikle doğrusal olmayan bir fonksiyon aracılığıyla bir çıktı üretir. ESA uygulamaları, girdileri görüntü şeklinde kabul eder ve bu özellikleri mimariye kodlamamıza olanak tanır. Bu ağlar, evrişim adı verilen özel bir matematiksel işlem kullandıkları için ESA olarak adlandırılır. Evrişim, belirli bir tür doğrusal işlemdir. Evrişimsel ağlar, derin öğrenme alanında en az bir katmanında genel matris çarpımı yerine evrişim işlemi kullanan sinir ağı türleridir (Goodfellow ve diğ., 2016).



Şekil 1:

Çalışmada kullanılan veri setinden bir örnek görüntüyle, akciğer hastalıklarını sınıflandırmak için tasarlanmış basit bir ESA mimarisi.

ESA'lar, temel olarak görüntü işleme görevlerinde kullanılan ve derin öğrenme mimarileri arasında yer alan özel bir sinir ağı türüdür. Şekil 1'de basit mimarisi verilen ESA'lar, evrişim katmanları, doğrultulmuş doğrusal birimler (ReLU), havuzlama katmanları ve tam bağlantılı katmanlar olmak üzere farklı katmanlardan oluşur. Bu katmanlar sayesinde ESA'lar, görüntülerdeki öznelikleri çıkararak ve sınıflandırarak görevlerini yerine getirir.

ESA'nın ilk ve en önemli katmanı olan evrişim katmanında, belirli boyutlarda filtreler, giriş görüntüsü üzerinde kaydırılarak görüntüdeki piksellerle çarpılır ve elde edilen sonuçlar toplanır. Bu işlem, tüm görüntü için tekrarlanır ve sonuç olarak bir öznelik haritası adı verilen yeni bir görüntü elde edilir. Evrişim katmanından sonra, ağırlık öğrenme hızını arttıran ve hesaplama yükünü azaltan ReLU (Rectified Linear Unit) adı verilen bir aktivasyon fonksiyonu uygulanır.

ReLU, pozitif girdileri olduğu gibi geçirirken, negatif girdileri sıfır olarak dönüştürür. Bu sayede, ESA daha hızlı ve verimli bir şekilde öğrenme gerçekleştirir. ReLU'nun bu özelliği, hiperbolik tanjant ve sigmoid gibi diğer aktivasyon fonksiyonlarına göre daha avantajlıdır. Havuzlama katmanı, filtreler yardımıyla öznitelik haritalarının, görüntünün özelliklerini kaybetmeden, boyutunun azaltılması için kullanılır. Yoğun katman olarak da bilinen tam bağlantılı katmanın amacı, önceki katmandaki her nöronu tam bağlantılı katmandaki her nörona bağlayarak giriş verilerindeki küresel desenleri ve ilişkileri yakalamaktır. Tam bağlantılı katman genellikle evrişim ve havuzlama katmanlarının ardına bağlanır ve o katmanlardan birkaç kez geçen ve matrise dönüşen görüntüyü düz bir vektöre dönüştürür. Son olarak, Softmax, çok sınıflı sınıflandırma problemleri için kullanılan ve giriş değerlerini bir olasılık dağılımına göre normalleştirip tüm çıkış değerlerinin toplamının 1 olmasını sağlayan bir aktivasyon fonksiyonudur.

3.1. Performans Ölçütleri

Derin öğrenme algoritmalarında, eğitimden sonra oluşturulan modelin kalitesini değerlendirmek, o modelin gerçek dünya koşullarında ne kadar iyi performans gösterdiğinin belirlenmesine yardımcı olur. Modellerin performanslarını değerlendirmede sıklıkla kullanılan metriklerden biri karışıklık matrisidir. Karışıklık matrisi (Confusion Matrix), gerçek değerler ile tahmin edilen değerlerden oluşan bir tablo olup, sınıflandırılan verilerden kaç tanesinin sınıflandırıcı tarafından doğru, kaç tanesinin yanlış sınıflandırıldığını gösterir. Derin öğrenme algoritmaları kullanan birçok sınıflandırma sistemi, performanslarını değerlendirmek için karışıklık matrisini kullanır. Karışıklık matrisinde 4 değer vardır. Doğru pozitif (TP), Yanlış pozitif (FP), Doğru negatif (TN), Yanlış negatif (FN). Bunlar:

TP gerçekte pozitif olup, modelin pozitif olarak tahmin ettiği,
TN gerçekte negatif olup, modelin negatif olarak tahmin ettiği,
FP gerçekte negatif olup, modelin pozitif olarak tahmin ettiği,
FN gerçekte pozitif olup, modelin negatif olarak tahmin ettiği
veri miktarlarıdır.

Tıbbi görüntülerin sınıflandırılmasında kullanılan yöntemlerin değerlendirilebilmesi amacıyla, karışıklık matrislerinden faydalanılarak, başarımlı ölçütü olarak doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skor ölçütleri uygulanmaktadır. Tablo 2'de denklemleri verilen bu ölçütler kısaca şöyle tanımlanabilir (Goodfellow ve diğ., 2016).

Doğruluk (Accuracy): Sınıflandırıcının test verisinin yüzde kaçının doğru olarak sınıflandırıldığını belirten metriktir. Modelin doğru sınıflandırdığı veri sayısının, tüm veri sayısına oranını gösterir.

Duyarlılık (Sensitivity veya Recall): Gerçek pozitif örneklerin sınıflandırılan pozitifler içindeki oranını ifade eder. Bu yüzden duyarlılık gerçek pozitif oranı olarak bilinmektedir.

Özgüllük (Specificity): Bir sınıflandırma algoritmasının, gerçekte negatif olan örnekleri doğru bir şekilde yani negatif olarak sınıflandırma oranıdır. Başka bir deyişle, gerçek negatif oranı olarak da bilinir.

Kesinlik (Precision): Sınıflandırılan pozitif örneklerin gerçek pozitifler içindeki oranını ifade eder.

F1 Değeri (F1-Score): Karşılaşılabilir her durumu hesaba katmak için duyarlılık ve kesinliğin harmonik ortalaması olarak alınır ve yöntemin genel doğruluğunu gösterir.

ROC Eğrisi (Receiver Operating Characteristic curve): Yanlış pozitif oranı (false positive rate) ile duyarlılık (recall) arasındaki ilişkiyi, bir sınıflandırma modelinin farklı kesme noktalarında gösteren bir grafikdir. Modelin duyarlılığını veya özgüllüğünü ayarlamak için kesme noktalarının seçimi kullanılır ve karar verme sürecinde esneklik sağlar.

AUC (Area Under the Curve): ROC eğrisinin altındaki alanı gösterir. Sınıflar arasında ayırt etme performansı, eğrinin altında kalan alan arttıkça artar. AUC, sınıflandırma modelinin tüm

duyarlılık ve özgüllük düzeylerindeki performansını tek bir sayı ile özetler. AUC değeri ne kadar 1'e yakınsa, kullanılan model o kadar kusursuz bir performansa sahip denir.

Modelin performans başarısı bu ölçütlerin sonuçlarının yüksekliği ile doğru orantılı olup, elde edilen değerler 1'e ne kadar yakınsa modelin uygulanabilirliği o kadar yüksek demektir. Tıbbi görüntüleme sistemlerine yönelik çalışmalarda bu değerlendirme metrikleri sıklıkla kullanılır. Bu çalışmada da bu ölçütler kullanılmıştır.

Tablo 2. İki Sınıflı bir ESA mimarisi için Karışıklık Matrisi

		Tahmin Edilen Sınıf		
		Pozitif	Negatif	
Gerçek Sınıf	Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)	Duyarlılık $\frac{TP}{(TP + FN)}$
	Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)	Özgüllük $\frac{TN}{(TN + FP)}$
		Kesinlik $\frac{TP}{(TP + FP)}$	Negatif Tahmin Değeri $\frac{TN}{(TN + FN)}$	Doğruluk $\frac{TP + TN}{(TP + TN + FP + FN)}$

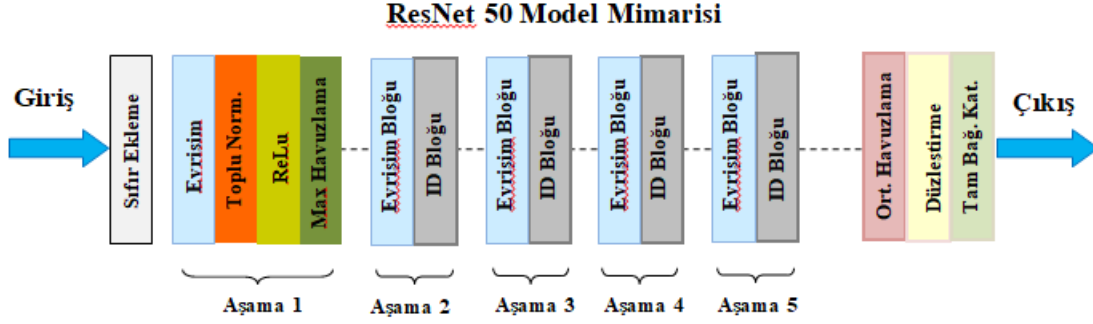
3.2. Sınıflandırıcılar

Bu bölümde, literatürde sıklıkla karşımıza çıkan, ResNet50, Inception v3, VGG16 ve AlexNet isimli 4 adet evrimsel sinir ağ mimarisi ile önerilen derin öğrenme modeli hakkında kısaca bilgi verilmiştir. Literatürde öne çıkan bu mimariler, 14 milyondan fazla etiketli görsel ve hayvanlardan bitkilere, taşıtlardan ev eşyalarına kadar geniş bir yelpazede 1.000'den fazla kategori içeren ImageNet veri seti ile eğitilmiştir.

3.2.1. ResNet (Residual Network-Artık Ağ)

2015 yılında Kaiming He ve arkadaşları tarafından görüntü tanıma için derin bir artık ağ (ResNet) önerilmiştir. ResNet'de katmanlar, referanssız öğrenme fonksiyonları yerine, katman girdilerini referans olarak öğrenen artık fonksiyonlar şeklinde yeniden formülize edilmiştir. 2019 yılında Raya Rahadian ve Suyanto, derin artık ağlar ile yüz tanıyarak yaş sınıflandırma probleminde 0,792 ortalama F1 değeri ile ResNet34'ün en iyi model olduğunu göstermiştir.

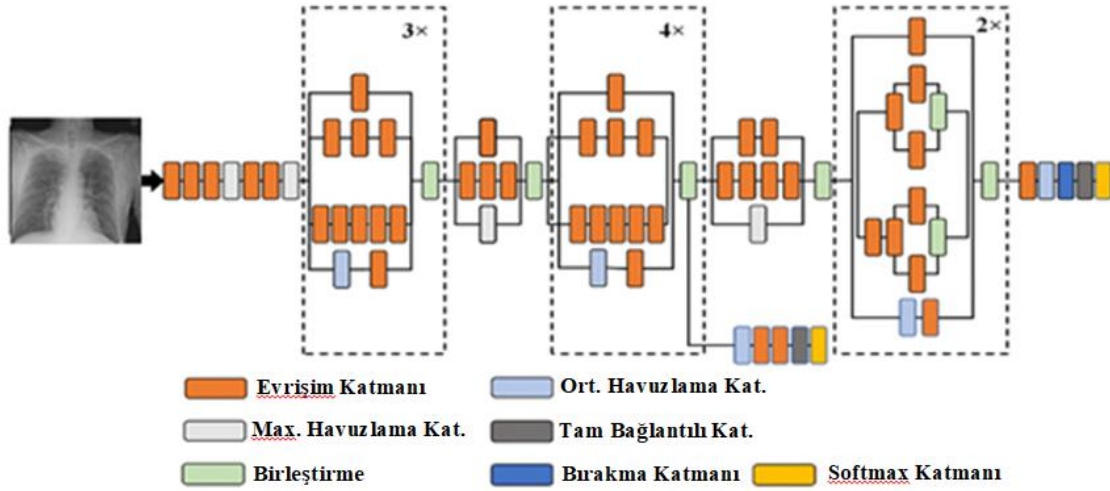
Adını 50 katmanlı oluşundan alan ResNet50 mimarisi; Şekil 2'de gösterildiği gibi, evrimsel katmanlar, kimlik bloğu (ID), evrimsel blok ve tam bağlantılı katmanlar olmak üzere dört ana kısımdan oluşur. Evrimsel katmanlar giriş görüntüsünden öznelikleri çıkarmaktan sorumludur, kimlik bloğu ve evrimsel blok ise bu öznelikleri işlemekten ve dönüştürmekten sorumludur. Son olarak, tam bağlı katmanlar en sondaki sınıflandırmayı yapmak için kullanılır. ResNet50'nin temel yapı taşları olan kimlik bloğu ile evrimsel blok arasındaki fark, giriş-çıkış boyutları olup, kimlik bloğunun giriş ve çıkış boyutları aynı, evrimsel bloğun ise farklıdır.



Şekil 2:
ResNet Mimarisi (Liu, C ve Niu, S., 2024)

3.2.2. Inception v3


Şekil 3’de mimarisi verilen Inception-v3, Christian Szegedy ve arkadaşları tarafından 2015 yılında tanıtılan Inception ailesinden bir evrişimli sinir ağıdır. Model, değişken çekirdek boyutları ve derinliklerine sahip birden fazla paralel evrişimsel katman kullanır ve bu da giriş görüntülerinde çok çeşitli öznitelikleri yakalamasına olanak tanır. Inception-v3, evrişimleri faktörize ederek parametre sayısını azaltır. Inception-v3, 48 katman derinliğinde önceden eğitilmiş bir evrişimli sinir ağı modelidir. Inception-v3, verimli mimarisi ve doğru sonuçları nedeniyle diğer bazı derin öğrenme modellerinden daha iyi kabul edilir.



Şekil 3:
Inception v3 Mimarisi (Liu, C ve Niu, S., 2024)

3.2.3. VGG-16

İlk kez 2015 yılında Oxford Üniversitesi Görsel Geometri Grubunda yer alan Andrew Zisserman ile Karen Simonyan tarafından tanıtılan VGG modeli, Şekil 4’de verildiği gibi, çok sayıda katmana sahip klasik bir derin ESA tasarımıdır ve VGG kısaltması Görsel Geometri Grubu anlamına gelir.

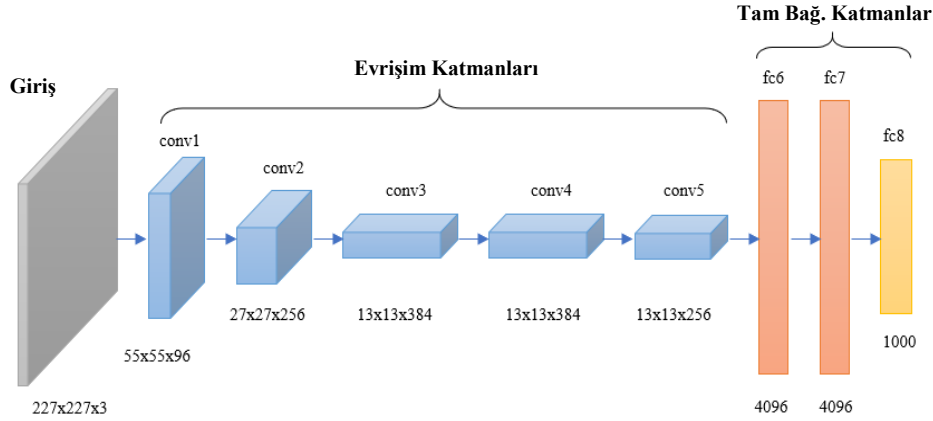


Şekil 4:
VGG-16 Mimarisi (Simonyan, K. ve Zisserman, A., 2015)

VGG16 ile ilgili en ilginç nokta, çok sayıda hiper parametreye sahip olmak yerine, 1 adımlı 3x3 filtrenin evrişim katmanlarına odaklanmış olmaları ve her zaman 2 adımlı 2x2 filtrenin aynı dolgusunu ve maxpool katmanını kullanmalarıdır. VGG16'daki 16, ağırlıkları olan 16 katmana sahip olduğunu ifade eder. Bu ağ oldukça büyük bir yapıya sahip olup, yaklaşık 138 milyon parametre içerir.

3.2.4. AlexNet

2012 yılında büyük ölçekli nesne algılama ve görüntü sınıflandırma algoritmaları için yapılan yarışma olan "ImageNet Büyük Ölçekli Görsel Tanıma Yarışması"nda Alex Krizhevsky ve takım arkadaşları tarafından sunulan ve birinciliği kazanan Alexnet, bir evrişimli sinir ağı mimarisidir.

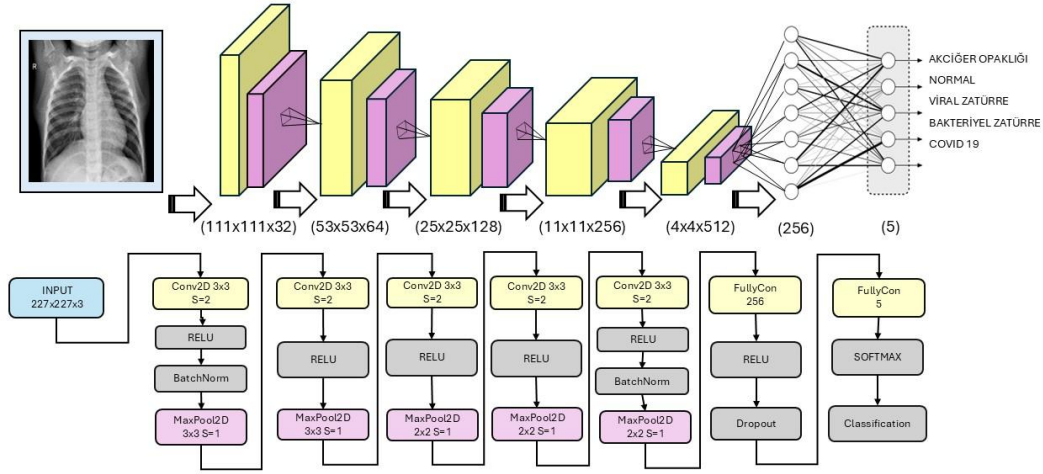


Şekil 5:
AlexNet Mimarisi (Putzu, L. ve diğ., 2020)

Bu mimari ile bilgisayarlı nesne tanıma sistemlerinde hata oranı %26,2'den %15,4'e düşürülmüştür. AlexNet'in mimarisi 5 konvolüsyon katmanı, havuzlama katmanı ve 3 tam bağlantılı katmandan oluşur. Şekil 5'de verilen Alexnet mimarisi, aynı anda 1000 nesneyi sınıflandıracak şekilde tasarlanmış olup yaklaşık 60 milyon parametreye ve 650.000 nörona sahiptir.

3.2.5. Önerilen Model (Özgün Tasarım)

Şekil 6'da detaylı yapısı verilen derin öğrenme modeli, göğüs röntgeni görüntülerinden akciğer hastalıklarını sınıflandırmak için tasarlanmış bir ESA mimarisidir. Girdi katmanı $227 \times 227 \times 3$ boyutunda görüntü alır ve ardından 3×3 filtreli, stride=2 olan Conv2D katmanları ve MaxPooling katmanları ile öznetelik çıkarımı yapılır. ReLU aktivasyon, Batch Normalization ve %50 Dropout katmanları modelin doğruluğunu ve genelleme yeteneğini artırır. Modelin derinliği 24 katman olup, küçük çekirdek boyutu ve kademeli filtre artışı ile parametre azaltma stratejisi uygulanmıştır. Bu 24 katmanın 18'i öğrenilebilir (trainable) yapıdadır. 256 nöronlu ve ardından 5 nöronlu tam bağlantılı katmanlar ile sınıflandırma yapılır. Softmax aktivasyon fonksiyonu sayesinde model, Akciğer Opaklığı, Normal, Viral Zatürre, Bakteriye Zatürre ve COVID-19 sınıflarına ayırır. Toplamda 3,6 milyon öğrenme parametresi ile model, detaylı öznetelik çıkarımı ve yüksek doğrulukta sınıflandırma için optimize edilmiştir.



Şekil 6:

Akciğer X-ray Görüntülerinden beş hastalık sınıfını tahmin etmek için tasarlanan özgün derin öğrenme modelinin mimarisi.

4. DENEYSEL ÇALIŞMA

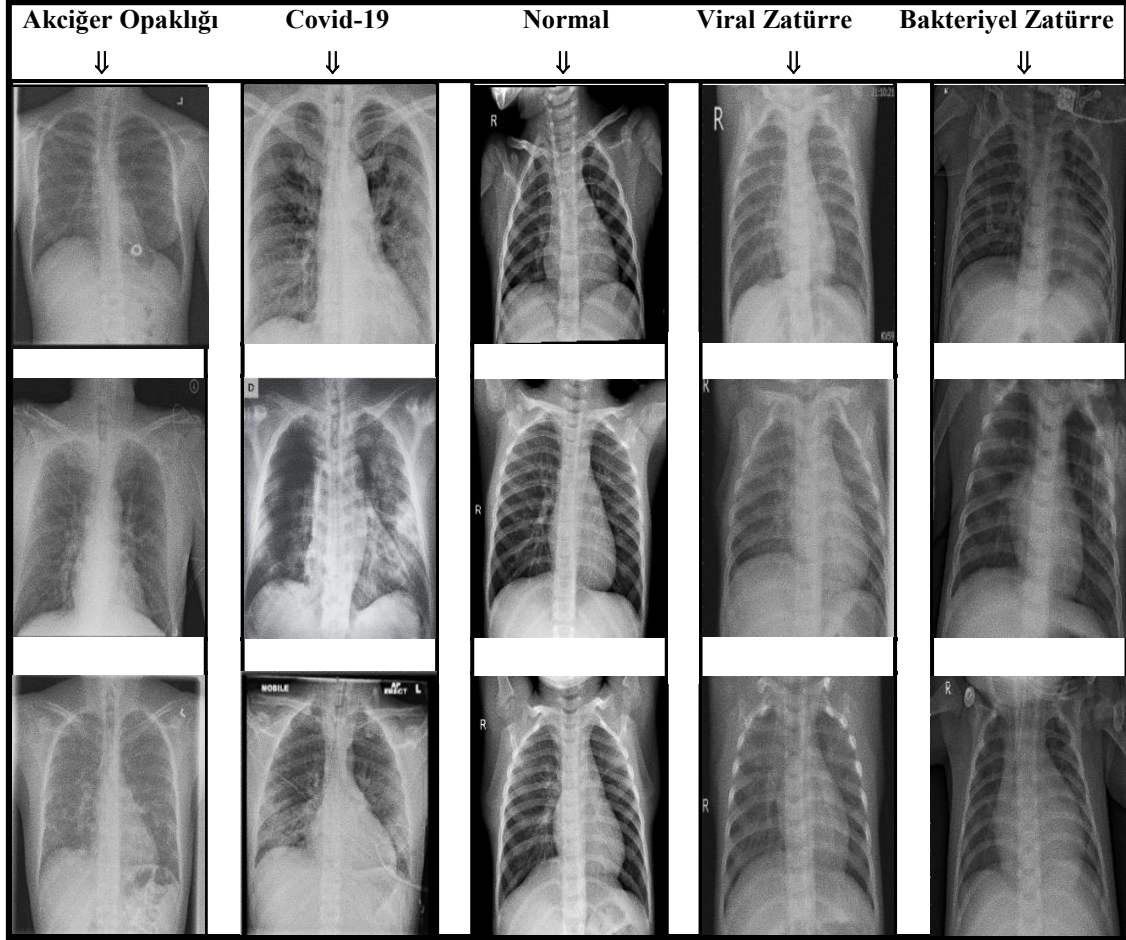
4.1. Veri Seti

Derin öğrenme ve ESA yapılarının en önemli unsurlarından biri doğru veri seti seçimidir. Bu çalışmada, araştırmacıların çalışabilmesi için Kaggle ve Mendeley Data üzerinden erişime açılmış olan, 2 farklı veri seti kullanılmıştır.

İlki Sachin Kumar tarafından 2022 yılında yayınlanan, 1626 adet Covid-19, 1800 adet Zatürre ve 1802 adet Normal (sağlıklı) bireylerin akciğer görüntüleri olmak üzere 3 sınıftan oluşan bir veri setidir. Görüntüler grayscale formatında ve boyutları birbirinden farklıdır.

İkinci veri seti ise Fatemeh Mehrparvar tarafından oluşturulan, 1125 adet akciğer opaklığına sahip hastalar, 1100 adet Viral Zatürre hastaları ile 1250 adet sağlıklı bireylerin akciğer görüntüleri olmak üzere yine 3 sınıftan oluşmaktadır. Görüntüler RGB formatında ve boyutları birbirinden farklıdır.

Bu iki veri setinden görüntüler rastgele şekilde, her bir sınıftan 500 adet olacak şekilde, seçilip toplamda 2500 görüntü verisi kullanılarak 5 sınıf içeren bir veri seti oluşturulmuştur. Oluşturulan veri setindeki 5 sınıfa ait X-ray görüntü örnekleri Şekil 7’de verilmiştir.



Şekil 7:
Veri setindeki 5 sınıfa ait X-ray görüntü örnekleri

Kumar’a ait ilk veri seti görüntüleri PhotoScape X uygulaması kullanılarak yeniden boyutlandırılıp 227x227 boyutuna dönüştürülmüştür. Ayrıca Mehrparvar’ın oluşturduğu ikinci veri seti görüntüleri RGB formatından grayscale formatına aynı uygulama ile dönüştürülmüştür. Bu işlemlerin sonunda isimleri; Akciğer Opaklığı, Covid, Normal, Viral Zatürre ve Bakteriyel Zatürre olan beş sınıf içeren bir veri seti elde edilmiştir. Bu veri setine herhangi bir veri artırımı uygulanmamıştır.

5 hastalık sınıfı için, her birine ait 500 adet olmak üzere, toplam 2500 görüntüden oluşturulan bu veri seti, Tablo 3’de gösterildiği gibi, %70 eğitim, %15 test ve %15 validasyon değerlerine bölünmüştür.

Tablo 3. Veri setindeki her bir sınıfa ait görüntü sayıları

	<i>Akciğer Opaklığı</i>	<i>Covid-19</i>	<i>Normal</i>	<i>Viral Zatürre</i>	<i>Bakteriyel Zatürre</i>
<i>Eğitim</i>	350	350	350	350	350
<i>Test</i>	75	75	75	75	75
<i>Validasyon</i>	75	75	75	75	75
<i>Toplam</i>	500	500	500	500	500

4.2. Derin Öğrenme Modelleri

Çalışmada yapılan analizler, 8 GB RAM ile 64 bit 2.40 GHz işlemciye sahip bir bilgisayara yüklü MATLAB uygulamasının R2022a sürümü kullanılarak gerçekleştirilmiştir.


Derin öğrenme modelleri ve giriş veri düzenlemeleri, önerilen özgün tasarım ağının oluşturulması ve parametre seçimi işlemleri, MATLAB ana sekmesinde yer alan Apps menüsündeki Deep Network Designer araç sekmesi kullanılarak yapılmıştır.

Bu çalışmadaki özgün model dışında kullanılan diğer ağlar, ImageNet veritabanındaki bir milyondan fazla görüntü üzerinde eğitilmiş olup, 1000 farklı kategori için zengin öznitelik çıkarımı yapabilmektedir. Kullanılan ağların özelliklerine ilişkin açıklamalar ise MathWorks sitesinden alınmıştır.

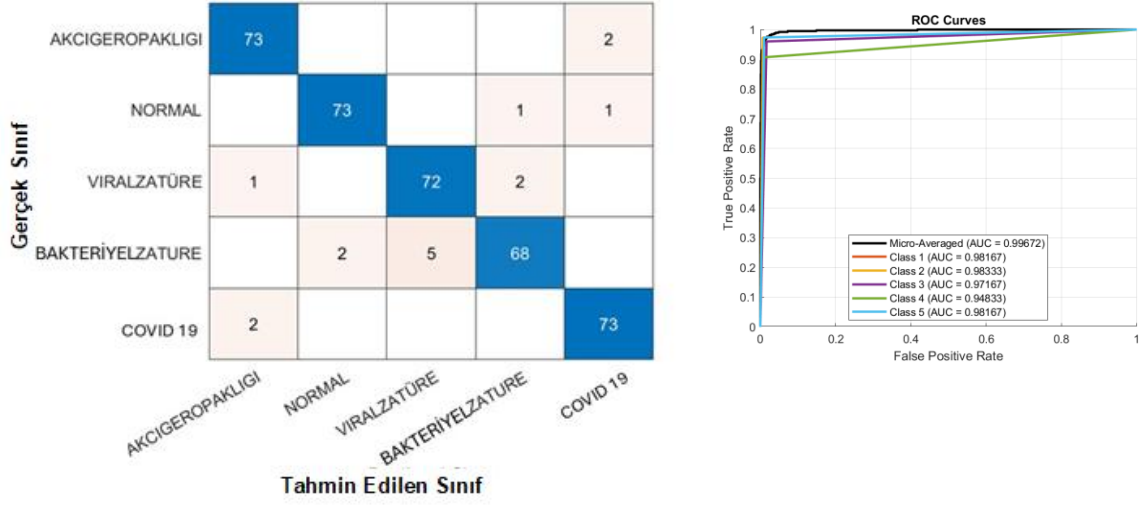
4.2.1. ResNet50

ResNet-50, 50 katman derinliğine sahip, 25,6 milyon parametre içeren ve yaklaşık 98 MB parametre hafızasına ihtiyaç duyan bir evrişimli sinir ağı olup, 224×224 boyutunda giriş görüntülerini kabul etmektedir.

Şekil 8’de ResNet50 modeli ile elde edilen doğruluk-kayıp grafiği, Şekil 9a’da modelin karışıklık matrisi ve Şekil9b’de ise modelin ROC eğrisi verilmiştir.



Şekil 8:
ResNet50 mimarisi için doğruluk- kayıp grafiği




Şekil 9:

a. ResNet50 mimarisine ait karışıklık matrisi b. ResNet50 mimarisine ait ROC eğrisi

4.2.2. Inception v3

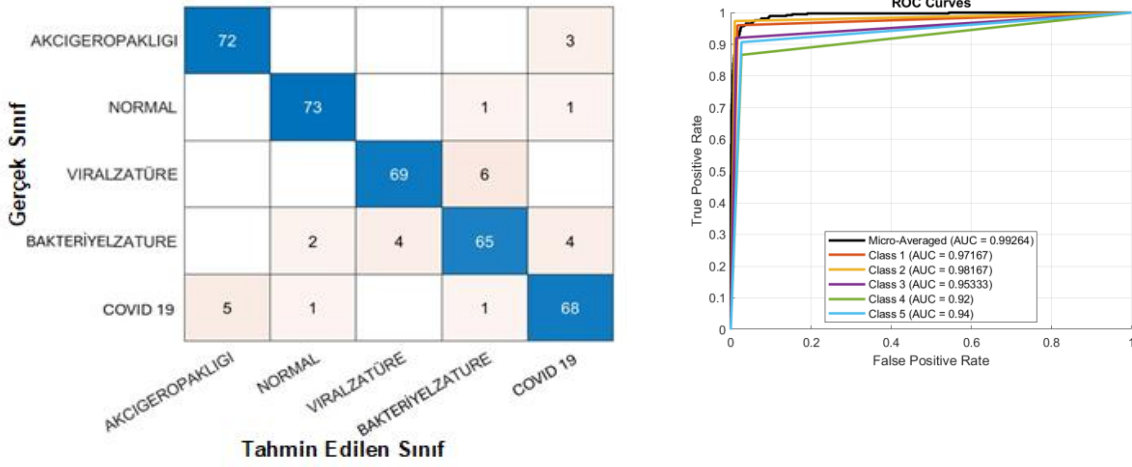
Inception-v3, giriş boyutu 299×299 olan görüntüler üzerinde çalışan, 48 katman derinliğinde bir CNN mimarisidir. Toplam 23,9 milyon parametre içeren bu ağın parametre hafızası yaklaşık 91 MB'dır.

Şekil 10'da Inception v3 modeli ile elde edilen doğruluk-kayıp grafiği, Şekil 11a'da modelin karışıklık matrisi ve Şekil 11b'de ise modelin ROC eğrisi verilmiştir.



Şekil 10.

Inception v3 mimarisi için doğruluk- kayıp grafiği



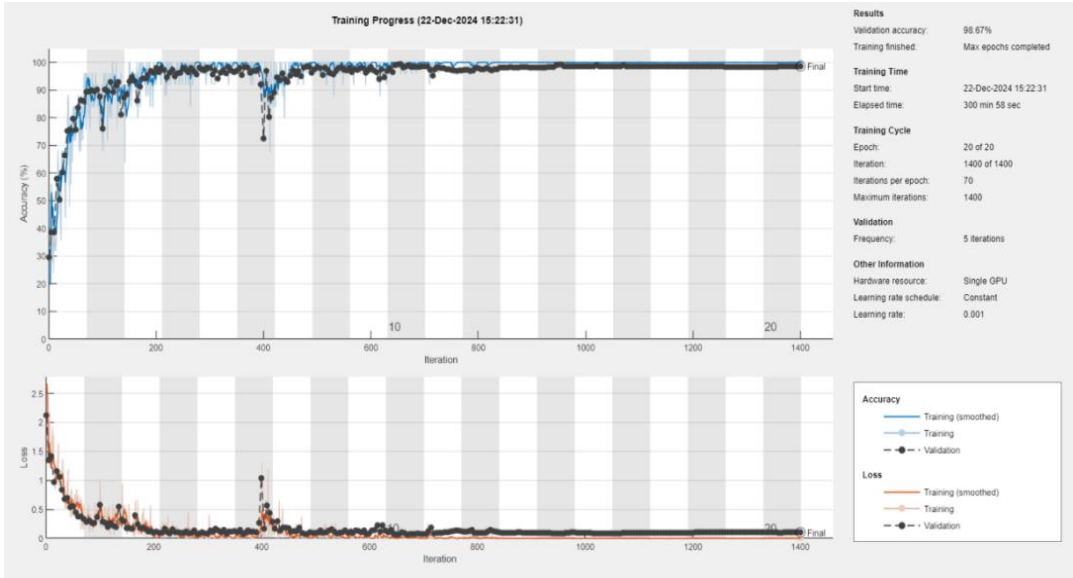
Şekil 11:

a. Inception v3 mimarisine ait karışıklık matrisi b. Inception v3 mimarisine ait ROC eğrisi

4.2.3. VGG16

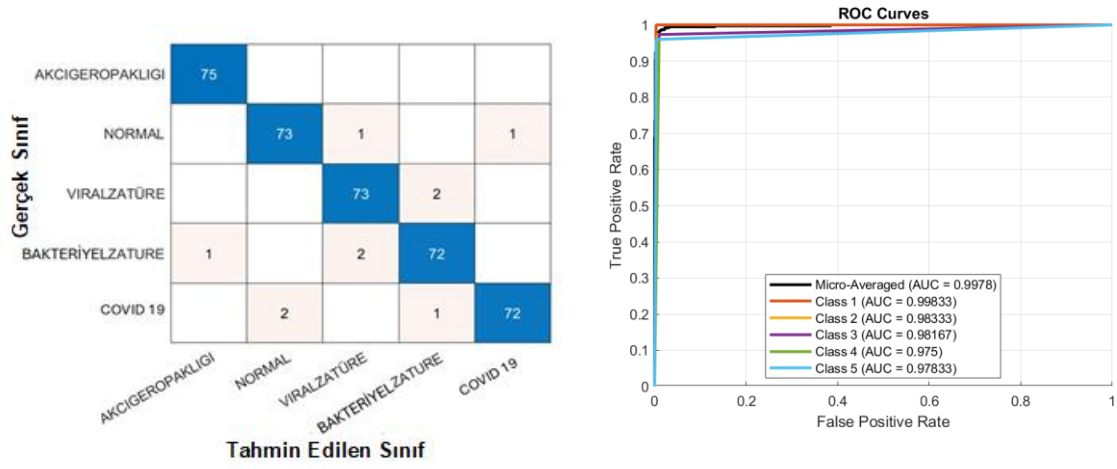
VGG-16, 224×224 boyutunda giriş görüntülerini işleyen, 16 katmanlı bir CNN mimarisidir. Ağ, yaklaşık 138 milyon parametre içerdiğinden 528 MB gibi büyük bir parametre hafızası gerektirmektedir

Şekil 12’de VGG16 modeli ile elde edilen doğruluk-kayıp grafiği, Şekil 13a’da modelin karışıklık matrisi ve Şekil 13b’de ise modelin ROC eğrisi verilmiştir.



Şekil 12:

VGG16 mimarisi için doğruluk- kayıp grafiği




Şekil 13:
a. VGG16 mimarisine ait karışıklık matrisi b. VGG16 mimarisine ait ROC eğrisi

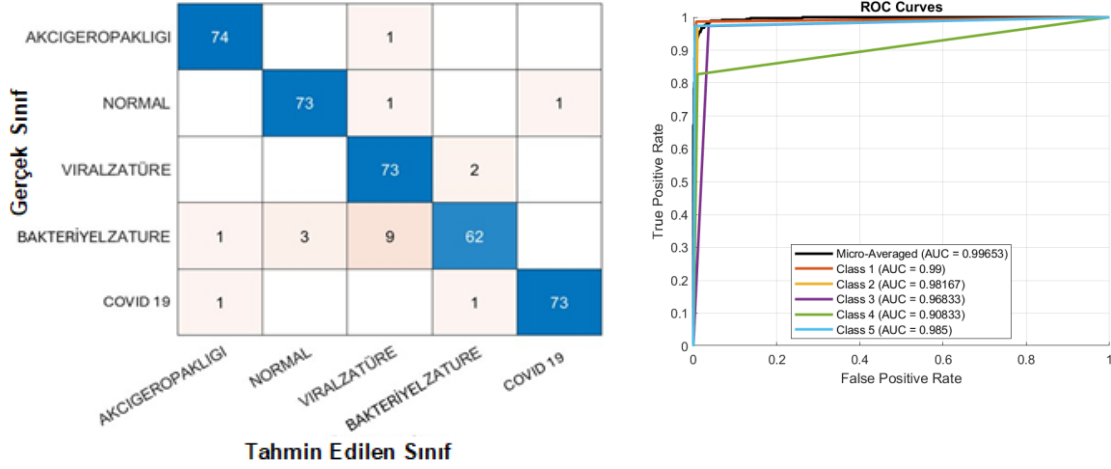
4.2.4. AlexNet

AlexNet, yaklaşık 61 milyon parametreye ve 233 MB parametre hafızasına sahip bir CNN modelidir. 8 katman derinliği bulunan ağ, 227×227 çözünürlüğündeki görüntüleri girdi olarak kabul etmektedir.

Şekil 14’de AlexNet modeli ile elde edilen doğruluk-kayıp grafiği, Şekil 15a’da modelin karışıklık matrisi ve Şekil15b’de ise modelin ROC eğrisi verilmiştir.



Şekil 14:
AlexNet mimarisi için doğruluk- kayıp grafiği



Şekil 15:

a. AlexNet mimarisine ait karışıklık matrisi


b. AlexNet mimarisine ait ROC eğrisi

4.2.5. Önerilen Model (Özgün Tasarım)

Önerilen (Özgün Tasarım) model, göğüs röntgeni görüntülerinden, Akciğer Opaklığı, Sağlıklı, Viral Zatürre, Bakteriyel Zatürre ve Covid-19 gibi akciğer hastalıklarını sınıflandırmak için tasarlanmış evrişimli sinir ağı mimarisidir. Girdi katmanı 227x227x3 boyutunda görüntü alır ve toplamda 3,6 milyon öğrenme parametresi ile model, detaylı öznetelik çıkarımı ve yüksek doğrulukta sınıflandırma için optimize edilmiştir.

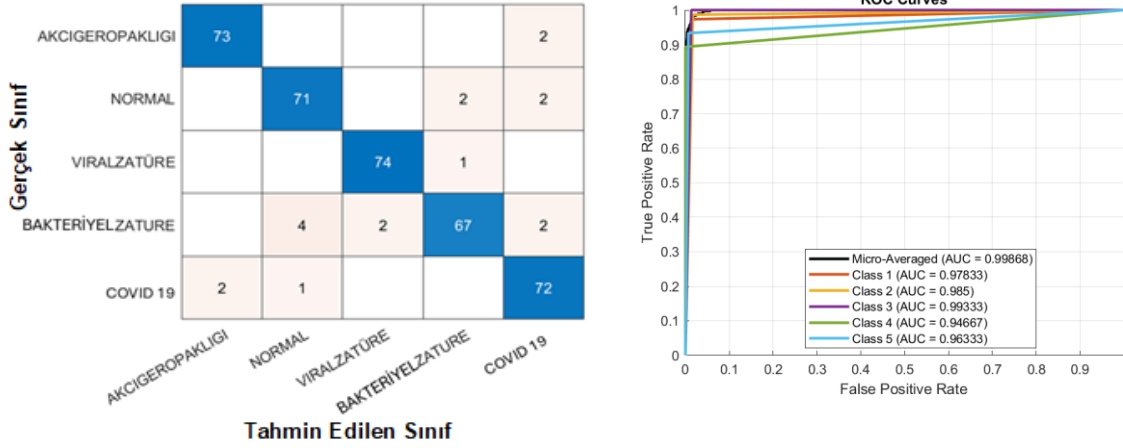
Eğitimin gerçekleştirilmesinde SGDM optimizasyon metodu kullanılmış; 64 mini-batch boyutu ile her epoch'ta 27 iterasyon olacak şekilde 40 epoch sonunda toplam 1080 iterasyon tamamlanmıştır.

Şekil 16'da Özgün Tasarım modeli ile elde edilen doğruluk-kayıp grafiği, Şekil 17a'da modelin karışıklık matrisi ve Şekil 17b'de ise modelin ROC eğrisi verilmiştir.



Şekil 16:

Özgün Tasarım mimarisi için doğruluk- kayıp grafiği



Şekil 17:

a. Özgün Tasarım mimarisine ait karışıklık matrisi

b. Özgün Tasarım mimarisine ait ROC eğrisi

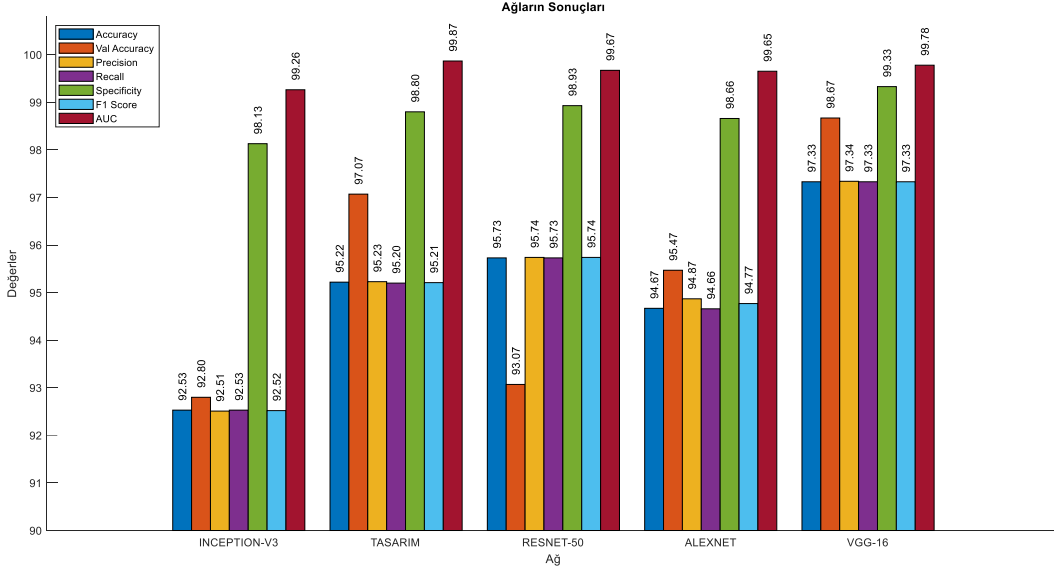
5. BULGULAR VE TARTIŞMA

Akciğer Opaklığı, Normal, Viral Zatlürre, BakteriyeZatlürre ve COVID-19 olmak üzere 5 sınıf üzerinde yapılan bu çalışmada, literatürde sıkça kullanılan dört farklı derin öğrenme modeline ek olarak özgün tasarlanmış bir modelin hastalık tespit performansı ölçülmüştür. Öncelikle, kullanılan derin öğrenme ağları hakkında detaylı bilgiler verilmiş, ardından bu ağların özellikleri ve elde edilen sonuçlar doğrultusunda performans değerleri karşılaştırılmıştır.

Tablo 4. Modellerin performans ölçütlerinin karşılaştırılması

	Doğruluk (Accuracy)	Kesinlik (precision)	Duyarlılık (recall)	Özgüllük (Specificity)	F1 Skor	AUC
RESNET 50	%95,73	0,9574	0,9573	0,9893	0,9574	0,99672
INCEPTION V3	%92,53	0,9251	0,9253	0,9813	0,9252	0,99264
VGG 16	%97,33	0,9734	0,9733	0,9933	0,97337	0,9978
ALEXNET	%94,67	0,9487	0,9466	0,9867	0,94769	0,99653
ÖZGÜN TASARIM	%95,22	0,9523	0,9520	0,9880	0,9521	0,99868

Tablo 4’de ResNet-50, VGG-16, Inception-v3, AlexNet ve tasarlanan özgün model olmak üzere toplam beş farklı model; doğruluk, kesinlik, duyarlılık, özgüllük, F1 skoru ve AUC değeri gibi çeşitli performans ölçütleri açısından karşılaştırılmıştır. Şekil 18 ise Tablo 4’de verilen değerlerin görsel değerlendirme kolaylığı için grafiğe aktarılmış halidir. Tablo 5’de ise modellerin doğruluk, validasyon doğrulukları, parametre sayıları, katman sayıları ve eğitim süreleri gibi faktörler de değerlendirilmiştir.



Şekil 18:

Modellerin performans ölçütlerinin karşılaştırılması

Modeller doğruluk, AUC ve F skoru açısından incelendiğinde en iyi sonucu veren ağ VGG-16 olmuş, sırasıyla ResNet-50, özgün tasarım ve AlexNet benzer sonuçlarla takip etmiş, en düşük performansı ise Inception-v3 göstermiştir. VGG-16 ağı en yüksek doğruluğa sahip olmasına rağmen, parametre sayısı diğer ağlardan oldukça fazladır ve yaklaşık 5 saat ile en uzun analiz süresine sahiptir. Özgün tasarım modeli ise 8 dakika 13 saniye gibi kısa bir sürede ve VGG-16'nın parametre sayısınının 40'ta biri olan 3,6 milyon parametreyle, yüksek doğruluk ve performans sergilemiştir. Ayrıca doğruluk ve performans ölçütleri birbirine çok yakın olan AlexNet ile özgün tasarım karşılaştırıldığında, performans parametreleri ve parametre sayısı açısından özgün tasarım avantaj sağlamıştır. Inception-v3 ise 2 saatlik analiz süresi ile diğer ağlara göre daha düşük performans göstermiştir. ResNet-50 ise yaklaşık 2,5 saat sürede analizini tamamlayarak, performans açısından önerilen özgün tasarım ve VGG-16 arasında bir sonuç elde etmiştir.

Tablo 5. Modellerin değişik parametrelerinin karşılaştırılması

	Doğruluk (Accuracy)	Validasyon Doğruluğu	Parametre Sayısı	Katman Sayısı	Analiz Süresi	Kayıp
RESNET 50	%95,73	%93,07	25,6 x10 ⁶	177	150 dk 3 s	0,1558
INCEPTION V3	%92,53	%92,80	23,9 x10 ⁶	315	117 dk 22 s	0,2772
VGG 16	%97,33	%98,67	138 x10 ⁶	41	300 dk 58 s	0,1010
ALEXNET	%94,67	%95,47	61 x10 ⁶	25	7 dk 10 s	0,1564
ÖZGÜN TASARIM	%95,22	%97,07	3,6 x10 ⁶	24	8 dk 13 s	0,1067

Modellerin performansları, test sonuçları ve karışıklık matrisleri üzerinden değerlendirildiğinde şu sonuçlar ortaya çıkmaktadır: ResNet-50 modeli, tüm sınıflarda yanlış tahminler yapmış olsa da en çok karıştırdığı sınıflar Viral Zatürre ve Bakteriyel Zatürre olmuştur. VGG-16 ağında ise Zatürre sınıfları ile Normal ve COVID-19 sınıfları arasında çift yönlü yanlış tahminler gözlemlenmiştir. Özellikle COVID-19 sınıfında yüksek oranda yanlış ve eksik tahminler yaparak en fazla hatayı bu sınıfta gerçekleştirmiştir. AlexNet, Viral Zatürre sınıfını neredeyse tüm diğer sınıflarla karıştırmış ve bu sınıfta belirgin bir tahmin hatası sergilemiştir. Inception-v3 modelinde ise Zatürre sınıfları ve COVID-19 sınıfında yoğun bir karışıklık yaşanmış, tahminlerde önemli yanlışlıklar meydana gelmiştir. Özgün tasarım modelinde ise COVID-19 ve Akciğer Opaklığı sınıfları ile Normal ve Bakteriyel Zatürre sınıflarında bazı yanlış tahminler yapılmıştır. Genel olarak değerlendirildiğinde, tüm modellerde Bakteriyel Zatürre ve Viral Zatürre sınıfları arasındaki tahmin hatalarının diğer sınıflara göre daha yüksek olduğu görülmektedir. Bununla birlikte, tüm modellerde en doğru tahmin edilen sınıfın Akciğer Opaklığı olduğu gözlemlenmiştir.

6. SONUÇ

Bu çalışmada, ResNet-50, VGG-16, Inception-v3, AlexNet ve 5 aşamalı evrişim ile kaskad bağlı 2 adet tam bağlantılı katmandan oluşan özgün tasarım derin öğrenme modellerinin, toplam 5 sınıf üzerinde hastalık tespit performansları incelenmiştir. Modellerin doğruluk başarımları, %92,53 ile %97,33 arasında değişmektedir. Çalışmadaki özgün tasarım (%95,22) ile ResNet-50 (%95,73) hemen hemen aynı doğruluk başarımına sahipken, özgün tasarımın analiz süresi 8dk 13sn ile ResNet-50'in süresinden 141dk 50sn daha kısadır. En yüksek doğruluğa sahip VGG16 (%97,33) modelinin analiz süresinin ise 300 dakika 58 saniye olduğu göz önüne alındığında, doğruluk-analiz süresi düzleminde pratik kullanımda diğer modellere göre dezavantajlıdır.

Bununla birlikte, modellerin performanslarını değerlendirmede yalnızca doğruluk oranının yeterli olmadığı bilinmektedir. Bu noktada AUC değeri önemli bir gösterge olarak öne çıkmaktadır. Özgün tasarımın AUC değeri 0,99868 ile tüm modeller arasında en yüksek değere ulaşmıştır. Bu sonuç, modelin sınıfları ayırt etme konusunda daha üstün bir performans sergilediğini, farklı karar eşiklerinde de tutarlı bir başarı gösterdiğini ve genel güvenilirlik açısından diğer mimarilerin önüne geçtiğini kanıtlamaktadır.

Sonuç olarak, önerilen özgün tasarım, hem hesaplama verimliliği hem de sınıflandırma başarısı açısından güçlü bir alternatif olarak değerlendirilebilir. Daha düşük parametre sayısı ve kısa analiz süresi ile pratik kullanım açısından avantaj sağlamakta; yüksek doğruluk, düşük kayıp ve en yüksek AUC değeri ile literatürdeki güçlü mimarilere karşı rekabetçi hatta birçok noktada üstün bir performans göstermektedir.

ÇIKAR ÇATIŞMASI

Yazarlar bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

YAZAR KATKISI

Hatice Doymaz çalışmanın kavramsal ve tasarım süreçlerinin belirlenmesi, veri toplama ve veri analizi, Figen Ertaş makale taslağının oluşturulması, veri analizi ve yorumlama kısımlarında katkı sağlamışlardır.

KAYNAKLAR

1. Afshar P, Heidarian S, Naderkhani F, Oikonomou A, Plataniotis KN, Mohammadi A. (2020) "Covid-caps: A capsule network-based framework for identification of covid-19 cases from X-ray images". *Pattern Recognition Letters*, Volume 138, 638–643. doi:10.1016/j.patec.2020.09.010
2. Ardila, D., Kiraly, A.P., Bharadwaj, S., Choi, B., Reicher, J.J., Peng, L., Tse, D., Etemadi, M., Ye, W., Corrado, G. (2019) "End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography", *Nature Medicine*, 25(6), 954–961. doi:10.1038/s41591-019-0447-x
3. Arun Prakash, J., Asswin, C., Ravi, V., Sowmya, V. ve Soman, K. P. (2023) "Pediatric pneumonia diagnosis using stacked ensemble learning on multi-model deep CNN architectures". *Multimedia Tools and Applications*, 82(14), 21311–21351. doi:10.1007/s11042-022-13844-6
4. Bouchareb Y, Moradi Khaniabadi P, Al Kindi F, Al Dhuhli H, Shiri I, Zaidi H, Rahmim A. (2021) "Artificial intelligence-driven assessment of radiological images for COVID-19", *Comp. in Biology and Medicine*, 136, 104665. doi: 10.1016/j.compbiomed.2021.104665.
5. Bozkurt, F. (2021) "Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti", *Avrupa Bilim ve Teknoloji Dergisi*, 24, 149-156. doi:10.31590/ejosat.898385
6. Brunese, L., Mercaldo, F., Reginelli, A., ve Santone, A. (2020) "Explainable deep learning for pulmonary disease and coronavirus COVID-19 detection from X-rays", *Computer Methods and Prog. in Biomedicine*, 24(10), 1559-1567. doi:10.1038/s41591-018-0177-5
7. Condaragiu, S. ve Ciocoiu, I. B. (2021) "Evaluation of convolutional neural networks for COVID-19 detection from chest X-ray images", *2021 International Symposium on Signals, Circuits and Systems ISSCS*, 1-4. doi:10.1109/ISSCS52333.2021.9497418
8. Coudray, N., Ocampo, P.S., Sakellaropoulos, T., Narula, N., Snuderl, M., David, F., Moreira, A.L., Razavian, N. ve Tsirigos, A. (2018) "Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning", *Nature Medicine*, doi:10.1038/s41591-018-0177-5
9. Demir, F. B. ve Yılmaz, E. (2021) "X-ray görüntülerinden COVID-19 tespiti için derin öğrenme temelli bir yaklaşım", *European Journal of Science and Technology*, Special Issue 32, 627-632, doi:10.31590/ejosat.1039522
10. Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M. ve Thrun, S. (2017) "Dermatologist-level classification of skin cancer with deep neural networks", *Nature*, 542, 115–118 (2017). doi:10.1038/nature21056
11. Goodfellow, I., Bengio, Y. Ve Courville, A. (2016) *Deep Learning*, The MIT Press
12. He, K., Zhang, X., Ren, S. ve Sun, J. (2015) "Deep residual learning for image recognition", *Computer Vision and Pattern Recognition*, doi:10.48550/arXiv.1512.03385v1
13. Ibrahim A. U., Ozsoz, M, Serte, S., Al-Turjman F. ve Yakoi P. S. (2021) "Pneumonia classification using deep learning from chest X-ray images during COVID-19", *Cognitive Computation*, 1-13. doi:10.1007/s12559-020-09787-5.
14. Ismael, A. M. ve Şengür, A. (2021). "Deep learning approaches for COVID-19 detection based on chest X-ray images", *Expert Sys. with App*, 164. doi: 10.1016/j.eswa.2020.114054
15. Khan A. I., Shah, J. L.ve Bhat, M. M. (2020) "Coronet: A deep neural network for detection and diagnosis of covid-19 from chest X-ray images", *Computer Methods and Programs in Biomedicine*, 196, 105581. doi:10.1016/j.cmpb.2020.105581
16. Krizhevsky, A., Sutskever I. ve Hinton, G. E. (2012) "ImageNet classification with deep convolutional neural networks" *Communications of the ACM*, 60, 84 - 90. doi:10.1145/3065386

17. Kumar, S. (2022), “Covid19-Pneumonia-Normal Chest X-ray Images”, Mendeley Data, V1, doi: 10.17632/dvntn9yhd2.1
18. Liu, C. ve Niu, S. (2024) “Automated Fruit Sorting in Smart Agriculture System: Analysis of Deep Learning-based Algorithms”, *International Journal of Advanced Computer Science and Applications, (IJACSA), Vol. 15, No. 1*, doi:10.14569/IJACSA.2024.0150183
19. Loey, M., Smarandache, F. Ve Khalifa, N. E. (2020) “Within the Lack of Chest COVID-19 X-ray Dataset: A Novel Detection Model Based on GAN and Deep Transfer Learning. *Symmetry*, 12, 651. doi:10.3390/sym12040651
20. MathWorks, Erişim Adresi: <https://www.mathworks.com/help/deeplearning/ref/>, (Erişim Tarihi: 02.12.2024)
21. Mehrparvar, F. , <https://www.kaggle.com/datasets/fatemehmehrparvar/lung-disease>
22. Nayak, S. R., Nayak, D. R., Sinha, U., Arora, V. ve Pachori R. B. (2021) “Application of deep learning techniques for detection of COVID-19 cases using chest X-ray images: A comprehensive study”, *Biomedical Signal Processing and Control*, 64:102365, doi:10.1016/j.bspc.2020.102365
23. Putzu, L., Piras, L., Giacinto, G. (2020) “Convolutional neural networks for relevance feedback in content based image retrieval”, *Multimedia Tools and Applications*, 79:26995–27021, doi:10.1007/s11042-020-09292-9.
24. Rahadian, R., ve Suyanto, S. (2019).” Deep residual neural network for age classification with face image”, *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 21-24. doi:10.1109/ISRITI48646.2019.9034664
25. Sevli O. (2022) “A deep learning-based approach for diagnosing COVID-19 on chest x-ray images, and a test study with clinical experts”, *Computational Intelligence*, (38), 1-25. doi: 10.1111/coin.12526.
26. Simonyan, K. ve Zisserman, . (2015) “Very deep convolutional networks for large-scale image recognition”, *The 3rd International Conference on Learning Representations (ICLR2015)*. doi:10.48550/arXiv.1409.1556
27. Singh, K. K., Siddhartha, M., ve Singh, A. (2020). “Diagnosis of Coronavirus Disease (COVID-19) from Chest X-Ray images using modified XceptionNet”, *Romanian Journal of Information Science and Technology*, 23(657), 91 -115.
28. Suzuki, K. (2017) “Overview of deep learning in medical imaging”. *Radiological Physics and Technology*. 10(3), 257-273. doi:10.1007/s12194-017-0406-5
29. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich A. (2015) “Going deeper with convolutions”. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, 7-12 June 2015, 1-9. doi:10.1109/CVPR.2015.7298594
30. Ullah, Z., Usman, M., Latif, S. ve Gwak, J. (2023) “Densely attention mechanism based network for COVID-19 detection in chest X-rays”, *Scientific Reports*, 13, 261. doi:10.1038/s41598-022-27266-9
31. Wang, L., Lin, Z. Q. ve Wong, A. (2020) “COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images,” *Scientific Reports*, 10(1). 19549. doi:10.1038/s41598-020-76550-z
32. WHO, (2020) World Health Organization: Use of Chest Imaging in Covid-19. 2020. Erişim Adresi: <https://www.who.int/publications/i/item/use-of-chest-imaging-in-covid-19> (Erişim Tarihi: 07.01.2025)
33. WHO, (2021), World Health Organization. (2021, August 28). *Coronavirus (COVID-19) Dashboard* Erişim Adresi: <http://covid19.who.int>. (Erişim Tarihi: 20.12.2024)
34. Wikipedia, (2024), COVID-19 pandemisi, .Erişim Adresi: https://tr.wikipedia.org/wiki/COVID-19_pandemisi (Erişim Tarihi: 20.12.2024)