



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI

**EVRİŞİMLİ SİNİR AĞLARI İLE AKCİĞER KANSERİ
SINIFLANDIRMASI**

YÜKSEK LİSANS TEZİ

Çimen UĞUR

Danışman

Doç. Dr. Mahir Kaya

TOKAT-2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre ve Doç. Dr. Mahir Kaya danışmanlığında hazırlamış olduğum “Evrişimli Sinir Ağları ile Akciğer Kanseri Sınıflandırması” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../.../...

Çimen UĞUR

JÜRİ KABUL VE ONAY



ÖN SÖZ

Bu tez Gaziosmanpaşa Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Programı'nda hazırlanmıştır. Yüksek lisans tezimin hazırlanma süresince bilgi, deneyim ve becerileriyle beni yönlendiren, desteklerini hiçbir zaman esirgemeyen ve takıldığım her konuda bana yardımcı olmaya çalışan kıymetli danışman hocam Doç. Dr. Mahir Kaya'ya sonsuz teşekkürlerimi sunarım. Çalışmalarım süresince desteklerini hiçbir zaman esirgemeyen sevgili aileme en içten teşekkürlerimi sunarım.

Çimen UĞUR

ÖZET

EVİRİŞİMLİ SİNİR AĞLARI İLE AKCİĞER KANSERİ SINIFLANDIRMASI

Uğur, Çimen

Yüksek Lisans, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Mahir Kaya

Şubat 2025, x + 53 sayfa

Kanser kaynaklı ölümlerin önde gelen nedenlerinden biri olan akciğer kanseri, geç evrede teşhis edilmesi ve erken dönemdeki semptomların belirgin olmaması nedeniyle önemli bir halk sağlığı sorunu olmaya devam etmektedir. Önlenebilir ölümlerin azaltılabilmesi için erken ve doğru teşhis büyük bir öneme sahiptir. Bu çalışmada, akciğer kanseri teşhisi için Evrişimli Sinir Ağları (ESA) ve transfer öğrenme yöntemlerini kullanarak ileri teknikler araştırılmıştır. Çalışmanın başlangıcında, veri setindeki farklı akciğer kanseri hastalarına ait görüntüler birleştirilerek ve normal hastaların bilgisayarlı tomografi görüntüleriyle birlikte ikili sınıflandırma yapılmıştır. Bu aşamada, en iyi modeli belirlemek amacıyla farklı mimariler ve hiperparametre optimizasyonları kullanılarak deneyler gerçekleştirilmiştir. Deneyler sonucunda, mimariler arasında en iyi performans gösteren model %93 doğruluk oranı sağlamıştır. Bir sonraki aşamada, veri seti başlangıç haline getirilerek çoklu sınıflandırma yapılmış ve çeşitli optimizasyon algoritmalarının performansları karşılaştırılmıştır. Optimizasyon algoritmaları olarak; Adam, SGD, RMSprop, Adadelta, Adagrad, Adamax ve Nadam algoritmaları kullanılmış ve Adam algoritması ile %87 doğruluk oranı elde edilmiştir. Aynı çalışma, veri setindeki verilerin artırılması yoluyla daha fazla akciğer görüntüsü kullanılarak tekrar edilmiştir ve RMSprop optimizasyon algoritması ile %96 doğruluk oranına ulaşılmıştır. Ayrıca, mevcut veri seti üzerinde transfer öğrenme kullanılarak son teknoloji modeller eğitilmiş ve test doğrulukları elde edilmiştir. Önerilen yöntem hem transfer öğrenme tabanlı yaklaşımlardan hem de literatürdeki benzer çalışmalardan daha yüksek doğruluk değerlerine ulaşmıştır. Geliştirilen model başarılı sonuçlar vererek doktorların karar verme sürecine katkı sağlayacaktır.

Anahtar Kelimeler: Evrişimli Sinir Ağları, Akciğer Kanseri, Transfer Öğrenme, Bilgisayarlı Tomografi, Hiperparametre Optimizasyonları

SUMMARY

LUNG CANCER CLASSIFICATION WITH CONVOLUTIONAL NEURAL NETWORKS

Uğur, Çimen

Master's Degree Computer Engineering Department

Thesis Advisor: Assoc. Dr. Mahir Kaya

February 2025, x + 53 Pages

Lung cancer, one of the leading causes of cancer-related deaths, remains an important public health problem because it is diagnosed at a late stage and early symptoms are not prominent. Early and accurate diagnosis is of great importance to reduce preventable deaths. In this study, we investigate advanced techniques for lung cancer diagnosis using Convolutional Neural Networks (CNNs) and transfer learning methods. At the beginning of the study, binary classification was performed by combining the images of different lung cancer patients in the dataset with the computed tomography images of normal patients. At this stage, experiments were conducted using different architectures and hyperparameter optimizations to determine the best model. As a result of the experiments, the best performing model among the architectures achieved 93% accuracy. In the next stage, the data set was initialised and multiclassified and the performances of various optimisation algorithms were compared. As optimization algorithms; Adam, SGD, RMSprop, Adadelta, Adagrad, Adamax and Nadam algorithms were used and an accuracy rate of 87% was obtained with the Adam algorithm. The same study was repeated using more lung images by increasing the data in the dataset and an accuracy of 96% was achieved with the RMSprop optimization algorithm. Furthermore, state-of-the-art models were trained using transfer learning on the existing dataset and test accuracies were obtained. The proposed method achieved higher accuracy values than both transfer learning based approaches and similar studies in the literature. The developed model will contribute to the decision-making process of doctors by providing successful results.

Keywords: Convolutional Neural Networks, Lung Cancer, Transfer Learning, Computed Tomography, Hyperparameter Optimizations

İÇİNDEKİLER

İçindekiler	Sayfa
ETİK SÖZLEŞME	i
JÜRİ KABUL VE ONAY.....	ii
ÖN SÖZ	iii
ÖZET	iv
SUMMARY	v
ŞEKİLLER LİSTESİ	viii
ÇİZELGELER LİSTESİ	ix
KISALTMALAR	x
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI	3
3. GENEL KISIMLAR.....	11
3.1 Akciğer Kanseri.....	11
3.1.1 Akciğer Kanseri Türleri	11
3.2 Akciğer Kanseri Teşhisinde Görüntüleme Teknolojileri	12
3.2.1 Bilgisayarlı Tomografi.....	12
3.2.2 Ultrasonografi (USG).....	12
3.2.3 Manyetik Rezonans Görüntüleme (MRG)	13
3.3 Derin Öğrenme Katmanları	13
3.3.1 Konvolüsyon Katmanı (Convolution Layer)	13
3.3.2 Maksimum Havuzlama Katmanı (MaxPooling)	14
3.3.3 Normalleştirme Katmanı (Normalization Layer).....	15
3.3.4 Bırakma Katmanı (Dropout)	15
3.3.5 Düzleştirme Katmanı (Flatten Layer)	16
3.3.6 Tam Bağlantılı Katmanı (Dense Layer)	17
3.4 Transfer Öğrenme Modelleri	17
3.4.1 VGG16	18
3.4.2 Resnet50	19
3.4.3 InceptionV3.....	19
3.4.4 DenseNet121	20
3.5 Optimizasyon Algoritmaları	20
3.5.1 SGD.....	20
3.5.2 Adagrad	21
3.5.3 RMSprop	21

3.5.4	Adam	21
3.5.5	Nadam	22
3.5.6	Adagrad	22
3.5.7	Adadelat	22
3.5.8	Adamax	22
3.6	Metrikler (Metrics)	23
3.6.1	Karışıklık Matrisi (Confusion Matrix)	23
3.6.2	F1 Puanı (F1 Score)	23
3.6.3	Duyarlılık (Recall)	24
3.6.4	Doğruluk (Accuracy)	24
3.6.5	Kesinlik (Precision).....	24
3.7	Çalışmada Kullanılan Programlama Dili.....	25
3.8	Veri Büyütme	25
3.9	Kayıp Fonksiyonu (Loss Function)	25
4.	MATERYAL VE METOT.....	27
4.1	Akciğer Görüntü Veri Seti.....	27
4.2	ESA Model Mimarisinin Belirlenmesi	29
4.3	Hiperparametreler ve Seçim Süreci.....	30
4.4	Optimizasyon Algoritmaları ve Çoklu Sınıflandırma	31
4.5	Transfer Öğrenme Yöntemi.....	32
5.	BULGULAR VE TARTIŞMA.....	33
6.	SONUÇ VE ÖNERİLER.....	46
7.	KAYNAKÇA.....	48

ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 3. 1. Konvolüsyon katmanı (Vdumoulin, 2023).....	14
Şekil 3. 2. Maksimum havuzlama katmanı.....	15
Şekil 3. 3. Bırakma katmanı (Srivastava ve ark., 2014)	16
Şekil 3. 4. Düzleştirme katmanı.....	17
Şekil 3. 5. VGG16 Mimari (Geek, 2024)	18
Şekil 3. 6. ResNet50 Mimarisi (WMC, 2021).....	19
Şekil 4. 1. Normal sınıfına ait akciğer tomografisi.....	28
Şekil 4. 2. Adenokarsinom hücreli akciğer tomografisi	28
Şekil 4. 3. Büyük hücreli karsinoma sahip akciğer tomografisi	29
Şekil 4. 4. Skuamöz hücreli karsinoma sahip akciğer tomografisi.....	29
Şekil 5. 1. Önerilen evrişimli sinir ağı mimarisi.....	35
Şekil 5. 2. Adam doğruluk grafiği	37
Şekil 5. 3. Adam için kayıp grafiği.....	37
Şekil 5. 4. Adam karmaşıklık matrisi gösterimi	38
Şekil 5. 5. RMSprop için doğruluk grafiği	40
Şekil 5. 6. RMSprop için kayıp grafiği.....	40
Şekil 5. 7. RMSprop karmaşıklık matrisi gösterimi	41
Şekil 5. 8. ResNet50 için doğruluk grafiği	42
Şekil 5. 9. ResNet50 için kayıp grafiği.....	42
Şekil 5. 10. ResNet50 karmaşıklık matrisi gösterimi	43
Şekil 5. 11. DenseNet121 için doğruluk grafiği	44
Şekil 5. 12. DenseNet121 için kayıp grafiği.....	44
Şekil 5. 13. DenseNet121 için karmaşıklık matrisi gösterimi	45

ÇİZELGELER LİSTESİ

	<u>Sayfa</u>
Tablo 2. 1. Literatür Analiz.....	10
Tablo 4. 1. Kaggle üzerinden alınan veri setinin düzenlenen hali	28
Tablo 4. 2. Kaggle üzerinden alınan veri seti üzerinde veri büyütme yapılarak genişletilmiş hale getirilen veri seti	28
Tablo 4. 3. Kullanılan hiperparametreler ve kısaltmaları	30
Tablo 5. 1. Yapılan deneysel çalışmalar	33
Tablo 5. 2. ESA Mimarisi: Katman Özellikleri ve Parametre Sayısı.....	35
Tablo 5. 3. Kaggle üzerinden alınan veri seti ile farklı optimizasyon algoritmaları kullanılarak elde edilen sonuçlar(orijinal veri seti)	36
Tablo 5. 4. Adam optimizasyon algoritması kullanılarak elde edilen sonuçlar (orjinal veri seti)	36
Tablo 5. 5. Kaggle üzerinden aldığımız orijinal veri seti ile veri büyütme yapılarak genişletilmiş veri seti kullanılarak farklı optimizasyon algoritmalar ile elde edilen sonuçlar	39
Tablo 5. 6. RMSprop optimizasyon algoritması kullanılarak elde edilen sonuçlar(genişletilmiş veri seti)	39
Tablo 5. 7. Kaggle üzerinden alınan veri seti içerisinde düzenleme yapılan seti ile transfer öğrenme kullanılarak elde edilen sonuçlar (orjinal veri seti)	41
Tablo 5. 8. Kaggle üzerinden aldığımız orijinal veri seti üzerinde veri büyütme yapılarak genişletilmiş veri seti ile transfer öğrenme kullanılarak elde edilen sonuçlar	43

KISALTMALAR

Adadelta	:Adaptive Delta
Adagrad	:Adaptive Gradient
Adam	:Adaptif Momentum
Adamax	:Maximum Adaptive Moment Estimation
BT	:Bilgisayarlı Tomografi
CAD	:Bilgisayar Destekli Teşhis
ConvLSTM	:Evrışimli Uzun Kısa Süreli Hafızalı Sinir Ağı
DNA	:Deoksiriboz Nükleik Asit
DÖ	:Derin Öğrenme
ESA	:Evrışimli Sinir Ağları
GP	:Gerçek Pozitif
GN	:Gerçek Negatif
KHAK	:Küçük Hücreli Akciğer Kanseri
KHDAK	:Küçük Hücreli Dışı Akciğer Kanseri
LSTM	:Uzun Kısa Dönem Hafıza
MRG	:Manyetik Rezonans Görüntüleme
Nadam	:Nesterov-Accelerated Adaptive Moment Estimation
Relu	:Doğrultulmuş Lineer Birim
RMSprop	:Root Mean Squared Propagation
SGD	:Stochastic Gradient Descent
USG	:Ultrason Görüntüleme
YN	:Yanlış Negatif
YP	:Yanlış Pozitif

1. GİRİŞ

Akciğer kanseri, özellikle gelişmiş ülkelerde halk sağlığı alanında önde gelen ölüm nedenlerinden biridir (Retico ve ark., 2008). Hastalığa yakalanan kişilerde inatçı öksürük, solunum güçlüğü veya açıklanamayan yorgunluk gibi belirtiler sıklıkla görülmektedir (ASM, 2024). Uluslararası Kanser Araştırmaları Ajansı'nın GLOBOCAN 2020 istatistiklerine göre, yaklaşık 1.8 milyon ölüm akciğer kanserine atfedilmiştir ve bu da hastalığın önemli küresel etkisinin altını çizmektedir (WHO, 2023). Tıp bilimindeki kayda değer ilerlemelere rağmen, akciğer kanseri küresel çapta kansere bağlı ölümlerin en önde gelen nedeni olmaya devam etmekte ve her yıl milyonlarca insanın hayatına mal olmaktadır (Temurtaş ve ark., 2019). Bu önemli halk sağlığı sorununu ele almak üzere, erken müdahale yoluyla önlenabilir ölümleri azaltmak için akciğer kanserine yönelik erken teşhis stratejileri geliştirilmektedir (Xie ve ark., 2019). Kanser erken aşamada tespit etmek hayat kurtarmak için çok önemlidir ve geleneksel olarak kanser teşhisi görsel inceleme ve manuel tekniklere dayanmaktadır. Bununla birlikte, tıbbi görüntülerin manuel olarak analiz edilmesi hem yoğun emek gerektirir hem de önemli hatalara açıktır (Munir ve ark., 2019). Otomatik teşhis yaklaşımları, uzmanların iş yükünü hafifleterek ve teşhis prosedürlerini hızlandırarak sağlık sistemi verimliliğini artırabilir (Kaya ve Çetin-Kaya, 2024a).

Çalışmamızda, birçok araştırmacının derin öğrenme tekniklerini kullanarak akciğer kanserini tespit etmeye çalıştığını gözlemledik. Bu yaklaşımlar arasında ESA bu alanda en sık kullanılan yöntemlerden biri haline gelmiştir (Krizhevsky ve ark., 2017). İleri beslemeli sinir ağlarına benzer şekilde; ESA'lar, konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlı katmanlar gibi temel katmanlar da dahil olmak üzere birçok katmandan oluşur. Bu katmanların farklı kombinasyonları çeşitli ESA oluşturmak için kullanılır (Kaya ve Çetin-Kaya, 2024b).

Mevcut çalışmalar, önerilen özel modellerin yeterince optimize edilmediğini ve transfer öğrenme modellerinin aşırı uyum nedeniyle küçük etiketli veri kümelerinde iyi performans göstermediğini göstermiştir. ESA modelleri çok sayıda hiperparametreye sahiptir. Modellerin sınırlı veri kümeleri üzerindeki yüksek performansı, bu hiperparametrelerin ince ayarına bağlıdır. Bu nedenle, yapılan çalışmada Bilgisayarlı Tomografi (BT) görüntülerini kullanarak akciğer kanserlerini hassas bir şekilde

tanımlamak için hazırlanmış, minimum katman sayısına sahip optimize edilmiş bir mimari tanıtılmaktadır. Çalışmada, Kaggle platformundan elde edilen açık erişimli akciğer Bilgisayarlı Tomografi görüntüleri kullanılmıştır. Çalışmanın başlangıç aşamasında, veri setindeki farklı akciğer kanseri hastalarına ait BT görüntülerini içeren klasörler birleştirilmiş ve normal hastalara ait görüntülerle birlikte ikili sınıflandırma yapılmıştır. Bu süreçte, en iyi modeli belirlemek için çeşitli mimariler ve hiperparametre optimizasyon yöntemleri test edilmiştir. Daha sonra, fotoğrafların orijinal hali korunarak, veri seti eski haline getirilerek çoklu sınıflandırma süreci gerçekleştirilmiştir. Bu aşamada, optimizasyon algoritmalarının performansları karşılaştırılmış ve Adam, SGD, RMSprop, Adadelta, Adagrad, Adamax ve Nadam gibi algoritmalar test edilmiştir. Ayrıca, Kaggle üzerinden alınan orijinal veri setindeki akciğer BT görüntülerinin sayısını artırmak amacıyla veri büyütme teknikleri uygulanmış ve aynı çalışmalar genişletilmiş veri seti üzerinde tekrar edilmiştir. İki veri seti arasında elde edilen sonuçlar karşılaştırılmıştır. Bunun yanı sıra, transfer öğrenme yöntemleri kullanılarak son teknoloji modeller eğitilmiş ve bu modellerin test doğrulukları değerlendirilmiştir. Kapsamlı deneyler sonucunda, kullanılan ESA mimarisinin tasarımını, karşılaştırılan optimizasyon algoritmalarını ve RMSprop'un üstün performansını ortaya koymaktadır. Bu sayede, akciğer kanseri için daha erişilebilir ve uygun maliyetli teşhis araçları geliştirilerek erken teşhis imkânı sağlanması ve hasta sonuçlarının iyileştirilmesi amaçlanmaktadır.

2. LİTERATÜR ARAŞTIRMASI

Literatüre baktığımızda akciğer kanseri tespitinde derin öğrenme kullanan birçok önemli çalışma bulunmaktadır. (Akila Agnes ve ark., 2021) yaptıkları çalışmada akciğer tümörü sınıflandırması üzerine çalışmışlardır. Yazarlar bilgisayarlı tomografi görüntüleri üzerinde Evrişimli Uzun Kısa Süreli Bellek (ConvLSTM) sinir ağı kullanarak sınıflandırma yapmış ve 0.93 doğruluk oranı elde etmişlerdir. ESA ve uzun kısa süreli bellek (LSTM) modelleri ile karşılaştırıldığında daha iyi sonuç elde edilmiştir.

(Rehman ve ark., 2021) bilgisayarlı tomografi görüntülerine uygulanan makine öğrenmesi yöntemlerini kullanarak akciğer kanserini tespit etmeye yönelik bir çalışma gerçekleştirmiştir. Yazarlar sadece kanseri değil aynı zamanda kanser türünü de tespit etmişlerdir ve bunlar adenokarsinom, skuamöz hücreli karsinom ve büyük hücreli karsinomdur. Destek vektör makinesi ve k-en yakın komşu yöntemleri ile test edilmiştir ve doğruluk oranları DVM için 0.93, k-en yakın için 0.91 olmuştur.

(Alakwaa ve ark., 2017) Data Science Bowl ve Kaggle'da akciğer BT görüntülerini sınıflandırmak için bir ESA önermiştir. LUNA veri kümesi içerisinde normal ve anormal olan görüntüler kullanılarak ikili sınıflandırma yapılmıştır. U-net ESA mimarisini kullanan yöntem ile 0.87 doğruluk oranı elde edilmiştir.

(Liao ve ark., 2019) BT taramalarından akciğer nodüllerinin tespiti ve sınıflandırılması için 3B ESA'ların kullanımını araştırmışlardır. Çalışma daha çok 3B taramalarda mevcut olan ve çeşitli boyutlardaki nodülleri tespit etme doğruluğunu artırmaya odaklanmış ve model performans ölçütü olarak 0.86'lık bir doğruluk elde etmiştir.

(Anthimopoulos ve ark., 2016) akciğer hastalıklarında çeşitli doku tiplerini sınıflandırmak için bir ESA modeli oluşturmuşlardır ve modellerinde 5 konvolüsyonel katman, 1 havuzlama katmanı ve 3 tam bağlı katman bulunmaktadır. Çalışmalarında, önerilen ESA algoritması; LeNet, AlexNet ve VGG Net gibi diğer algoritmalara kıyasla 0.86 doğrulukla doku sınıflandırma ve tespitinde daha iyi sonuçlar elde etmiştir.

(Song ve ark., 2017) çalışmalarında BT görüntülerini iyi huylu ve kötü huylu olarak sınıflandırmak için LIDC-IDRI veri kümesini kullanmışlardır. Veri kümesi ESA, Derin Sinir Ağları (DNN) ve Yığılmış Otomatik Kodlayıcılar (SAE) gibi mimariler kullanılarak analiz edilmiştir. ESA mimarisi, önerilen diğer ağlardan daha iyi performans göstermiş ve 0.84 doğruluk, 0.83 duyarlılık ve 0.84 özgüllük ile en yüksek performansı göstermiştir.

(Ashhar ve ark., 2021) LIDC-IDRI veri kümesini kullanarak akciğer tümörlerinin kötü huylu ve iyi huylu olarak sınıflandırılmasında beş farklı ESA mimarisinin performansını incelemeyi amaçlamıştır, değerlendirilen mimariler DenseNet, MobileNetV2, ShuffleNet, SqueezeNet ve GoogleNet'tir. Bu mimarilerin performansı doğruluk, duyarlılık, özgüllük ve (AUC) performans değerlerine göre ölçülmüş ve GoogleNet'in BT görüntülerinde akciğer tümörü sınıflandırması için 0.95 doğruluk, 0.99 özgüllük, 0.65 duyarlılık ve 0.86 AUC ile en başarılı ESA mimarisi olduğunu göstermiştir.

(Mohamed ve ark., 2023), akciğer kanseri teşhisinin doğruluğunu artırmak için bir ESA modelini hibrit bir meta sezgisel algoritma ile entegre eden yenilikçi bir yöntem sunmuştur. Önerilen hibrit modelde, ESA mimarisinin çözüm vektörünü geliştirmek için Ebola Optimizasyon Arama Algoritması (EOSA) uygulanmaktadır. İlk olarak, bir ESA mimarisi tasarlanmıştır ve çözüm vektörü hesaplanmıştır, bu çözüm vektörü daha sonra sınıflandırma problemini çözmek için ağırlıkların ve önyargıların optimum kombinasyonunu belirlemek üzere EOSA'ya aktarılmıştır. Irak Onkoloji Eğitim Hastanesi / Ulusal Kanser Hastalıkları Merkezi'nden bir akciğer kanseri veri kümesi kullanılarak yapılan deneylerde, EOSA-ESA modeli 0.87 doğruluk elde etmiştir.

(Tan ve ark., 2022) transfer öğrenmeyi kullanan özel bir VGG16 tabanlı 15 katmanlı 2B DNN mimarisi kullanmıştır. Bu DNN modeli, Ulusal Akciğer Tarama Denemesi ve Ulusal Alerji ve Bulaşıcı Hastalıklar Enstitüsü Portallarından elde edilen BT görüntü setleri üzerinde eğitilmiş ve test edilmiştir. Sonuçlar, DNN'nin 0.90'lık bir F1 puanı ve 0.90'lık bir doğruluk elde ettiğini göstermiştir.

(Sravani ve ark., 2024) yaptıkları çalışmada, LUNA16 veri setinden seçilen 746 akciğer görüntüsü kullanmıştır. Veri seti nodüllü, nodülsüz akciğerler görüntülerini içermektedir. VGG16 modeli kullanılarak, 0.99 doğruluk oranıyla InceptionV3'ün 0.88'lik başarısını geride bırakmıştır. Önerilen VGG16 modeli, üstün doğruluk ve sağlamlık sergilemiştir.

(Khalefa, 2024) çalışmalarında, Sonlu Elemanlar Yöntemi (FEM), Derin Otomatik Kodlayıcı (DAE) ve Evrişimli Sinir Ağı tekniklerini birleştiren FEM-DESA adlı yeni bir model sunulmuştur. LIDC-IDRI veri seti kullanılarak, akciğer nodülü tespiti ve akciğer kanseri teşhisi için sağlam bir model geliştirilmiştir. FEM, DAE ve ESA entegrasyonunda hesaplama karmaşıklığını azaltırken DAE, BT taramalarındaki özellikleri çıkarmada etkili olmuştur. Önerilen model, 12 katmanda tek ESA algoritmasına göre daha yüksek doğruluk göstermiştir 0.97 doğruluk oranıyla FEM-DESA, tek ESA'dan daha üstün bir performans sergilemiştir.

(Xu ve ark., 2022) çalışmalarında, ESA tabanlı çok kategorili bir sınıflandırma modeli olan ISANET önerilmiştir. Akciğer skuamöz hücreli karsinomu, akciğer adenokarsinomu ve normal kategorilerini içeren Hebei Üniversitesi Bağlı Hastanesi veri kümesi ile Kaggle ve TCIA veri setleri kullanılarak deneyler gerçekleştirilmiştir. ISANET, AlexNet, VGG16, InceptionV3, MobilenetV2 ve ResNet18 gibi modellerle karşılaştırıldığında, Kaggle veri seti için 0.95, TCIA için 0.98 Hebei için 0.99 doğruluk oranlarıyla üstün performans sergilemiştir.

(Mitra ve ark.,2023) yaptıkları çalışmada, akciğer kanseri tespiti için ESA kullanılmıştır. Kaggle'dan alınan 1000 görüntü, adenokarsinom, skuamöz hücreli karsinom ve normal olmak üzere üç kategoriye ayrılmıştır. ESA modelleri, gizli katman sayılarına göre dört kategoriye ayrılmış ve farklı parametrelerle test edilmiştir. En iyi doğruluk 0.93, 4 katmanlı, veri büyütme katmanı olmayan ve Adam optimize edici kullanılan modelde elde edilmiştir.

(Geethu Lakshmi ve Nagaraj, 2024) yaptıkları çalışmada, akciğer kanseri teşhisi için Slime Mould Algorithm (SMA) tabanlı ESA özelliklerine sahip Squeeze-Inception V3 adlı bir teknik geliştirmiştir. Veri seti, 1001 BT taraması görüntüsünden oluşmakta olup adenokarsinom, büyük hücreli karsinom, skuamöz hücreli karsinom ve normal sınıflarını içermektedir çalışma sırasında manuel olarak elde edilen normal ve anormal olarak sınıf oluşturulmuştur. Göğüs BT tarama görüntüleri üzerinde yapılan çalışmada, ön işleme aşamasında görüntü kalitesi artırılmış, SMA ile eğitilen ESA kullanılarak özellikler çıkarılmış ve SqueezeNet ile InceptionV3 mimarilerinin birleşimiyle normal ve anormal sınıflandırma yapılmıştır. Önerilen model, 0.95 doğruluk, 0.98 hassasiyet ve 0.94 özgüllük oranlarıyla üstün performans göstermiştir.

(Yan ve Razmjoooy, 2023) çalışmalarında BT görüntülerinde akciğer kanserinin otomatik tespiti için yeni bir metodoloji önermiştir. ESA tabanlı olan bu model, optimize edilmiş bir Snake Optimizasyonu algoritması kullanılarak geliştirilmiştir. Akciğer kanseri görüntüleri ön işleme tabi tutulduktan sonra, hiperparametreleri optimize edilmiş ESA yapısına entegre edilmiştir. Model, IQ-OTH/NCCD-Akciğer Kanseri Veri Seti ile değerlendirilmiş ve 0.97 doğruluk elde etmiştir. Önerilen yöntem, KNN, CFM, WSDL, CLFM ve DFD-Net gibi mevcut tekniklerden üstün performans göstermiştir.

(Su ve ark., 2021) çalışmalarında LIDC-IDRI veri tabanından alınan verilerle akciğer nodüllerinin tespiti için optimize edilmiş Faster R-ESA yöntemi önermiştir. Akciğer nodülleri, soliter pulmoner nodül, vasküler adezyon pulmoner nodülü ve akciğer duvarı adezyon pulmoner nodülü olarak sınıflandırılmıştır. Yapılan analizlerde, önerilen yöntem 0.91 doğruluk oranı ile orijinal Faster R-ESA 0.82, R-ESA 0.68 ve Fast R-ESA 0.75 değerleri elde edilerek önerilen yöntemin diğer algoritmalarından üstün performansı görülmüştür.

(Zhang ve ark., 2024) Bu çalışma, akciğer kanseri tanımlama ve sınıflandırması için DenseNet ile güçlendirilmiş ESA ve veri birleştirme ile mobil uç bilişim teknolojilerini birleştiren bir yaklaşım sunmaktadır. Görüntüler, özellik çıkarımını optimize etmek için ön işleme tabi tutulmuştur. Model, akciğer hastalıklarını normal, iyi huylu ve adenokarsinom, skuamöz hücreli karsinom, büyük hücreli karsinom olarak kategorize etmektedir. Sonuç olarak, 0.99 doğruluk elde etmiştir.

(Karim ve Bushra, 2021) çalışmada, akciğer kanseri türlerini yüksek doğrulukla tanıyabilen bir Evrişimli Sinir Ağı modeli önerilmektedir. LC25000 Akciğer ve Kolon Histopatolojik Görüntü Veri Seti'nden alınan 15.000 akciğer histopatoloji görüntüsü, iyi huylu doku, adenokarsinom ve skuamöz hücreli karsinom olarak üç kategoriye ayrılmıştır. Model, 6 evrişim katmanı ve 3 yoğun katmandan oluşmakta olup, 3x3 çekirdek boyutunda sırasıyla 32, 64, 128, 128, 128 ve 64 filtre kullanmaktadır. Deneysel bulgular, eğitimde 0.98 ve doğrulamada 0.98 doğruluk oranları elde etmiştir.

(Ren, Z. ve ark., 2022) yaptıkları çalışmada üç sınıf içeren bir veri seti kullanarak akciğer kanseri sınıflandırması için veri büyütme ve topluluk öğrenme yöntemini kullanmıştır. Önerilen LCDAE framework'ü, LDCGAN ile sentetik akciğer kanseri görüntüleri

 reterek veri eksikliğini gidermiř ve altı farklı derin  ğrenme modelini (DenseNet121, GoogLeNet, ResNet101, VGG19-BN, VGG16-BN ve VGG16) hibrit veri b y tme teknikleriyle eęiterek sınıflandırma performansını artırmıřtır. 15.000 g r nt den oluřan veri seti, LDCGAN ile 45.000 g r nt ye geniřletilmiř ve transfer  ğrenme ile 1.00 doęruluk elde edilmiřtir. Ayrıca, Alzheimer, beyin t m r  ve COVID-19 veri setlerinde de y ksek bařarı g steren LCDAE, tıbbi g r nt  analizinde GAN tabanlı veri b y tme y ntemlerinin etkisinin iyi olduęunu kanıtlamaktadır.

(Sultana ve ark., 2021) yaptıkları  alıřmada, Kaggle'dan alınan akcięer ve kolon kanseri histopatolojik g r nt lerinden oluřturulan bir veri seti kullanılmıřtır. Veri seti, her biri 5.000 g r nt  i eren    alt klas re ayrılmıřtır: iyi huylu dokusu, adenokarsinom ve skuam z h creli karsinomu.    akcięer kanseri t r  i in 2-B ESA ile SVM, ResNet-50, InceptionResNetV2, Inception-V3 ve VGG-19 gibi beř derin  ğrenme modeli uygulanmıřtır. Inception-V3, 0.99 doęrulama doęruluęu ile en iyi performansı g stermiřtir ve akcięer kanseri t rlerini doęru sınıflandırmak i in en uygun model olarak belirlenmiřtir.

Derin  ğrenme modellerinde veri  n iřleme ařamasında veri artırımı teknikleri yaygın bir řekilde kullanılmaktadır. Evriřimli Sinir Aęı modellerinde de  eřitli tekniklerle g r nt  bařına veri artırımını eęitimden  nce veya eęitim ařamasında uygulayan  eřitli  alıřmalar mevcuttur

(Sajjad ve ark., 2019) beyin t m rlerinin MRI g r nt leri  zerinden sınıflandırılması i in derin  ğrenme tabanlı bir y ntem  nermiřtir.  alıřmada, InputCascadeCNN modeli ile otomatik t m r segmentasyonu ger ekleřtirilmiř, veri b y tme teknikleri kullanılarak modelin genelleme yeteneęi iyileřtirilmiř ve VGG-19 ESA mimarisiyle sınıflandırma yapılmıřtır.  alıřmada Radiopaedia ve beyin t m r  veri setleri kullanılmıřtır. Veri b y tme sonrasında genel doęruluk 0.91'e y kselmiřtir. Yapılan  alıřmada  zellikle transfer  ğrenme ve veri b y tme tekniklerinin model performansını artırdığı g zlemlenmiřtir.

(Gurkahraman ve Karakiř, 2021)  alıřmalarında gliyom, menenjiyom ve hipofiz bezi t m rleri, T1 aęırlıklı MR g r nt leri kullanılarak ESA ile sınıflandırılmıřtır.  alıřmada Figshare veri seti kullanılmıřtır, 233 hastaya ait toplam 3064 kesit i ermektedir. Modelin

performansını artırmak için veri büyütme teknikleri (geometrik dönüşümler ve görsel filtreler) uygulanmıştır. Her MRI kesitinden 10 farklı görüntü üretilmiştir. ESA modeli, DenseNet121 tabanlı transfer öğrenme yöntemi ile eğitilmiş ve RMSProp optimizasyon algoritması kullanılmıştır. Modelin veri büyütme öncesi doğruluk oranı 0.95 iken, veri büyütme sonrası 0.99'a yükselmiştir. Ayrıca, ESA'dan elde edilen özellikler DVM, KNN ve Bayes gibi alternatif sınıflandırıcılarla test edilmiş, en yüksek doğruluk 1.00 ile DVM tarafından elde edilmiştir. Bu sonuçlar, transfer öğrenme ve veri büyütme tekniklerinin beyin tümörü sınıflandırmasında başarıyı artırdığını ve alternatif sınıflandırıcılarla yapılan karşılaştırmaların derin öğrenme modellerinin etkinliğini ortaya koyduğunu göstermiştir.

(Benbakreti ark., 2023) tarafından yapılan çalışmada, sagittal, koronal ve aksiyel MR görüntülerinden menenjiyom, gliyom, hipofiz tümörü ve tümörsüz beyin görüntülerinin sınıflandırılması için derin öğrenme modelleri kullanılmıştır. Çalışmada, ESA tabanlı bir model ile birlikte AlexNet, GoogleNet, ResNet18, YOLOv3, VGG19, DenseNet ve MobileNet gibi önceden eğitilmiş modeller test edilmiştir. Veri seti, 2005-2010 yılları arasında Çin'in Guangzhou kentindeki Tianjing Tıp Üniversitesi ve Nanfang Hastanesi'nden toplanan 233 hastaya ait 3264 MR kesitinden oluşmaktadır. Modelin başarısını artırmak için yansıma tabanlı veri büyütme teknikleri uygulanmış ve eğitim veri seti genişletilmiştir. Deneysel çalışmalar sonucunda önerilen ESA modeli 0.90 doğruluk elde etmiştir. Ancak, en iyi performans 0.96 doğruluk ile ResNet18 modeli tarafından sağlanmıştır. Bununla birlikte, aşırı veri büyütme bazı durumlarda model performansını düşürmüştür. Çalışma, beyin tümörü tespiti için önceden eğitilmiş modellerin etkili olduğunu ve veri büyütmenin model başarısını genel olarak iyileştirdiğini ortaya koymuştur.

(Claro ve ark., 2022) yaptıkları çalışmada, 18 farklı kamuya açık veri setinden 3.536 kan slaydı görüntüsü kullanılarak dört farklı sınıf (Sağlıklı Kan Slaydı, Akut Lenfoblastik Lösemi, Akut Miyeloid Lösemi ve Diğer Lösemi Türleri) üzerinde sınıflandırma yapmıştır. Veri setindeki sınıf dengesizliğini gidermek amacıyla dönme, öteleme, çevirme ve ölçekleme gibi geometrik dönüşümlere dayalı veri büyütme teknikleri uygulanmıştır. Sınıflandırma işlemi için AlexNet, VGG16, VGG19, ResNet50, InceptionV3, Xception ve DenseNet121 olmak üzere yedi farklı ESA modeli kullanılmıştır. Elde edilen sonuçlara göre, ikili sınıflandırmada en yüksek doğruluk

oranları ResNet50 ve DenseNet121 modelleriyle sağlanmıştır. Lösemi ve sağlıklı kan slaydı ayrımı için ResNet50 modeli 1.00 doğruluk elde ederken, ALL ve sağlıklı kan slaydı ayrımı için DenseNet121 modeli 1.00 doğruluk göstermiştir. Çok sınıflı sınıflandırmada ise DenseNet121 modeli 0.97 doğrulukla en iyi sonucu vermiştir. Tüm sınıfların birlikte değerlendirildiği bölümde ise en iyi performans 0.95 doğruluk ile multilevel ESA modeli tarafından elde edilmiştir. ESA tabanlı derin öğrenme modelleri ile veri büyütme tekniklerinin birleşiminin, lösemi sınıflandırma performansını önemli ölçüde artırdığını göstermektedir.

(Saini ve Susan, 2020) çalışmalarında dengesiz meme kanseri histopatolojik görüntü veri setinin iyi huylu ve kötü huylu olarak sınıflandırılması için Derin Aktarım Öğrenme ve Azınlık Veri Artırımı tekniklerinin birleştirildiği yöntemler önerilmiştir. Çalışmada VGG16 tabanlı derin aktarım ağı ve DCGAN modeli entegre edilerek sınıf dengesizliği giderilmiş ve BreakHis veri seti üzerinde 0.96 doğruluk elde edilmiştir. DCGAN ile azınlık sınıfına ait sahte görüntüler üretilerek veri dengelenmiş ve bu yaklaşım, geleneksel transfer öğrenme yöntemlerine kıyasla daha yüksek doğruluk sağlamıştır. Elde edilen sonuçlar, biyomedikal görüntü analizi için derin öğrenme tabanlı veri büyütme tekniklerinin etkinliğini göstermiştir.

(Alsaif, H., ve ark., 2022) çalışmalarında, beyin tümörlerinin MRI görüntülerinde tespiti için veri büyütme teknikleri kullanılarak ikili sınıflandırma işlemi ile VGG-16 modeli optimize edilmiştir. Kaggle'dan alınan 253 görüntü, çevirme, döndürme ve çeviri teknikleriyle 3700 görüntüye genişletilmiş ve farklı segmentasyon modelleriyle karşılaştırılmıştır. Veri büyütme teknikleri, Cascaded Net, U-Net ve Deeplab-v3 modellerinin Dice skorlarını %2-3 oranında iyileştirmiştir. Transfer öğrenme ile yapılan karşılaştırmalarda VGG-16 modeli 0.96 doğruluk ile en iyi performansı göstermiştir. Sonuçlar, veri büyütme yöntemlerinin sınırlı veri problemiyle başa çıkmada ve model başarısını artırmada etkili olduğunu ortaya koymaktadır.

(Cuşkun, Y. ve ark., 2023) çalışmalarında, beyin tümörü olan hastaların MR görüntülerinden primer beyin metastaz yerinin sınıflandırılması amaçlanmıştır. Kocaeli Üniversitesi PACS sisteminden elde edilen 298 hastaya ait MR görüntüleri, dört farklı dizi (T1, T1-C, FLAIR ve ADC) ayrı evrimsel işlemlerden geçirilerek 3B ESA modeli ile analiz edilmiştir. Üç grup sınıflandırmasında 0.74, ikili sınıflandırmada ise 0.81 doğruluk elde edilmiştir. Veri büyütme teknikleri uygulanarak üç grup sınıflandırmasında

doğruluk 0.76'ya yükseltilmiştir. Önerilen ESA modelinin sınırlı veriyle başarılı sınıflandırma yapabildiğini ve veri büyütme yöntemlerinin modelin doğruluğunu artırmada etkili olduğunu göstermektedir.

(Talo, M. ve ark., 2019) yaptıkları çalışmada, manyetik rezonans görüntülerinde normal ve anormal beyin görüntüleri tespiti için derin öğrenme yöntemlerinden transfer öğrenme yaklaşımı kullanılmıştır. ResNet34 ESA modeli temel alınarak yapılan çalışmada, Harvard Tıp Fakültesi'nden alınan 613 T2 ağırlıklı MR görüntüsü değerlendirilmiştir. Modelin genelleme yeteneğini artırmak için veri büyütme, optimum öğrenme oranı belirleme ve ince ayar teknikleri uygulanmıştır. Üç aşamalı eğitim sürecinde, model önce yalnızca yoğun katmanları eğiterek başlatılmış, ardından tüm katmanlar üzerinde ince ayar yapılmıştır. Model, 5 katlı çapraz doğrulama ile 0.98 doğruluk elde etmiş ve ince ayar sonrasında 1.00 doğruluğa ulaşmıştır. Öğrenme oranı optimizasyonu ve veri büyütme yöntemleri modelin doğruluk ve stabilitesini artırmada etkili olmuştur.

Tablo 2. 1. Literatür Analiz

Çalışmalar	Model	Yıl	Doğruluk (%)	Sınıflandırma
Agnes ve ark.	ConvLSTM	2020	93	İkili
Rehman ve ark.	Dvm	2021	93	Çoklu
Song ve ark.	ESA	2017	84	İkili
Ashhar ve ark.	GoogleNet	2021	95	İkili
Mohamed ve ark.	EOSA-ESA	2023	87	Çoklu
Tan ve ark.	DNN	2022	90	İkili
Alakwaa ve ark.	U-net ESA	2017	87	İkili
Liao ve ark.	3B ESA	2019	86	İkili
Anthimopoulos ve ark.	ESA	2016	86	Çoklu
Sravani ve ark.	VGG16	2024	99	İkili
Khalefa	FEM-DESA	2024	97	İkili
Xu ve ark.	ISANET	2022	99	Çoklu
Mitra ve ark.	ESA	2023	93	Çoklu
Geethu Lakshmi ve Nagaraj	Squeeze-Inception V3	2024	95	İkili
Yan ve Razmjoo	Snake-ESA	2023	97	Çoklu
Su ve ark.	Faster R-ESA	2021	91	Çoklu
Zhang ve ark.	DenseNet-ESA	2024	99	Çoklu
Ren ve ark.	ESA	2022	95	Çoklu
Karim ve Bushra	ESA	2021	98	Çoklu
Sultana ve ark.	Inception-V3	2021	99	Çoklu

3. GENEL KISIMLAR

Bu bölümde, çalışmada kullanılan temel kavramlar ve yöntemler ele alınmaktadır. İlk olarak akciğer kanseri ve teşhisinde kullanılan görüntüleme teknolojileri tanıtılmakta, ardından derin öğrenme katmanları, transfer öğrenme modelleri ve optimizasyon algoritmaları gibi makine öğrenmesi yöntemleri detaylandırılmaktadır. Ayrıca, model performansını değerlendirmek için kullanılan metrikler ile veri büyütme teknikleri açıklanmaktadır. Bu konuların incelenmesi, yapılan çalışmanın bilimsel altyapısını oluşturmakta ve elde edilen sonuçların yorumlanmasını desteklemektedir.

3.1 Akciğer Kanseri

İnsan vücudu, kendi işlevleri ve amacı olan trilyonlarca canlı hücreden oluşmaktadır. Çok yönlü bir hastalık olan kanser hastalığı vücudun belirli bir bölgesindeki hücrelerin DNA (Deoksiriboz nükleik asit) hasarı nedeniyle kontrolsüz bir şekilde büyüyerek kanserli hücrelere dönüşmesi ile ortaya çıkmaktadır (ACS,2014). Tüm tümörler kötü huylu değildir; kanserli olmayan tümörler ise iyi huylu tümör olarak adlandırılmaktadır. Sigara içme alışkanlıkları, özellikle erkeklerde sıkı tütün kontrolü önlemleri nedeni ile azalan eğilimler var olmasına rağmen görülme sıklığının önemli ölçüde yüksek kaldığı gelişmiş ülkelerde, akciğer kanseri oranlarının artmasına ağırlıklı olarak katkıda bulunmaktadır (Youlden ve ark., 2008). Akciğer kanseri, 40 yaşın üzerindeki erkeklerde kadınlarda ise 59 yaşın üzerinde sıklıkla görülmektedir ve ilginç bir şekilde, sigara içmeyenler arasında kadınların akciğer kanserine yakalanma olasılığı erkekler ile karşılaştırıldığında yüksek olduğu görülmüştür (Siegel ve ark., 2018). Akciğer kanserinin doğru teşhis edilmesi, hasta yönetiminde çok önemli bir faktör olarak ortaya çıkmaktadır; teşhis anındaki evre, hayatta kalma sonuçlarını önemli ölçüde etkileyen önemli bir etkidir.

3.1.1 Akciğer Kanseri Türleri

Akciğer kanserinin her birinin kendine özgü özellikleri bulunan farklı türleri vardır. Akciğer kanserinin başlıca türleri ise küçük hücreli olmayan akciğer kanseri (KHDAK) ile küçük hücreli akciğer kanseridir (KHAK) (ACS, 2024). Tüm kanserler gibi akciğer kanseri de akciğer dokularında bulunan bir hücrenin kontrolsüz büyümesi olayıdır ve akciğer kanseri iki ana türe ayrılır:

i- Küçük hücreli dışı akciğer kanseri (KHDAK): Akciğer kanserlerinin en sık görülen türü küçük hücreli dışı akciğer kanseridir ve farklı alt türlere ayrılmaktadır (TTOD, 2024). Bunların her biri farklı kanser hücrelerine sahiptir ve farklı şekillerde büyümekte ve yayılmaktadır. Küçük hücreli dışı akciğer kanseri türlerinin adlandırılması kanserde bulunan hücre türlerine ve hücrelerin mikroskop altında nasıl görüldüğüne göre yapılmıştır. Sık görülen küçük hücreli dışı akciğer kanseri türleri arasında skuamöz hücreli karsinom, büyük hücreli karsinom ve adenokarsinom bulunmaktadır.

ii- Küçük hücreli akciğer kanseri (KHAK): Akciğer kanserinde küçük hücreli akciğer kanseri daha az rastlanan tür olarak yer almaktadır (TTOD, 2024).

3.2 Akciğer Kanseri Teşhisinde Görüntüleme Teknolojileri

Tıbbi görüntülemede tanısal verileri bulmak için, ultrasonografi, manyetik rezonans görüntüleme (MRG) ve bilgisayarlı tomografi (BT), olmak üzere çeşitli yöntemler kullanılmaktadır. Tıbbi görüntüleme sağlık hizmetlerinde teşhis doğruluğunu artırma, tedavi planlamasının yapılmasında ve izlenmesine yardımcı olmaktadır ve bu sayede kronik hastalık yönetimi, tıbbi araştırmalar gibi çalışmalarını daha kolay hale getirmektedir.

3.2.1 Bilgisayarlı Tomografi

Bilgisayarlı Tomografi, bir hastanın vücudundaki belirli bölgelerin enine kesit görüntülerini elde etmek için kullanılan bir tıbbi görüntüleme yöntemidir. Bu işlem, farklı açılardan ve konumlardan alınan röntgen verilerinin birleştirilmesiyle gerçekleştirilir. BT, incelenmek istenen alanı dijital olarak dilimlere ayırarak ayrıntılı görüntüler oluşturur (Türkçetin, 2019). Bu dilimlere tomografik görüntüler denir ve bu görüntüler, bir klinik hekime geleneksel röntgen ışınlarına kıyasla daha ayrıntılı bilgiler sunabilir. Bilgisayar, hastanın ardışık dilimlerini toplayarak bu görüntüleri dijital ortamda birleştirir ve böylece üç boyutlu bir görüntü elde etmektedir (Karaca, 2023).

3.2.2 Ultrasonografi (USG)

Ultrasonografi (USG), ultrason görüntüleme olarak da bilinen, organların ve dokuların gerçek zamanlı görüntülerini elde etmek amacıyla yüksek frekanslı ses dalgalarını kullanan bir yöntemdir (Kim ve ark., 2024). Ayrıca, makine öğreniminin yüksek frekanslı

ultrason ile entegrasyonu, tıbbi teşhis süreçlerinde yeni bir süreç yaratarak erken hastalık tespiti, kişiselleştirilmiş tedavi planları ve daha iyi hasta sonuçları için yeni olanaklar sağlamaktadır (Kim ve ark., 2024).

3.2.3 Manyetik Rezonans Görüntüleme (MRG)

Manyetik rezonans görüntüleme (MRG), nükleer manyetik rezonans (NMR) fenomenine dayanan bir görüntüleme yöntemi olup, tıp alanında tanı amaçlı yüksek çözünürlüklü ve yüksek kontrastlı görüntüler elde etmek için kullanılmaktadır. İyonlaştırıcı radyasyon kullanılmadığından, bu yöntem, X-ışını bilgisayarlı tomografi gibi diğer görüntüleme teknolojilerinden ayrılmaktadır. MRG hem statik hem de dinamik olabilen üstün kontrasta sahip yumuşak ve sert doku görüntüleri sunar ve bu işlem, statik veya yavaş değişen manyetik alanlar ile elektromanyetik (EM) enerjiye dayanmaktadır (Karaca, 2023). Dalga boyu dokunun fiziksel boyutundan büyük olsa bile, MRG ile yumuşak dokuların yüksek çözünürlüklü görüntüleri başarıyla elde edilebilmektedir (Karaca, 2023).


3.3 Derin Öğrenme Katmanları

Derin öğrenme, temel olarak veriye ilişkin sınıflandırılmış özelliklerin eğitilmesine dayanmaktadır. Bu sebeple, düşük seviyeli özellikler bir araya getirilir ve daha üst düzey özellikleri içeren bir özellik hiyerarşisi meydana getirilmektedir. Örneğin, bir görüntü söz konusu olduğunda özellik denildiğinde, piksel yoğunluk değerlerinden oluşan bir vektör ya da kenar grupları ve özel şekiller gibi unsurlar akla gelebilir. Bu özellikler arasında, veriyi daha iyi açıklayanlar bulunmaktadır. Başarılı bir derin öğrenme modellemesi gerçekleştirebilmek için geniş bir veri kümesine, bu verileri eğitecek bir yönteme, özelliklerin sınıflandırılmasına, katman sayısının belirlenmesine dair birçok unsur dikkate alınmalıdır (Akın ve Şahin, 2023).

3.3.1 Konvolüsyon Katmanı (Convolution Layer)

Evrişimli sinir ağlarında kullanılan doğrusal fonksiyon, evrişimli katman olarak adlandırılmaktadır. Bu katmanda, gizli katmandaki her bir düğüm, görüntü işleme için belirli özellik dedektörleri kullanarak farklı özellikler çıkarmaktadır (Salomon ve Phelan, 2018). Örnek verirsek, ilk katmandaki bir düğüm yatay kenarları algılamak, bir diğeri


dikey kenarları tespit edebilir. Şekil 3.1’de, adımli evriřim iřleminin bir g r nt   zerinde nasıl  alıřtıđını g stermektedir. Alt kısımda orijinal g r nt  yer alırken,  stte evriřim iřlemlerinin  ıktısı g r lmektedir. Ayrıca, evriřim iřleminin  ıktısının orijinal g r nt n n boyutlarını k   ltt đ n  de unutmamak gerekir.



 ekil 3. 1. Konvol syon katmanı (Vdumoulin, 2023)

3.3.2 Maksimum Havuzlama Katmanı (MaxPooling)

Maksimum havuzlama katmanı genellikle evriřimli katmandan sonra uygulanmaktadır. Havuzlamanın temel amacı, evriřimli katmandan elde edilen boyutları daha da k   ltmek ve modelin sađamlıđını artırmaktır. Bu s re te, sadece  nemli  zellikler  ıkarılarak modelin performansı iyileřtirilir ve havuzlama iřlemi iki řekilde ger ekleřtirilir: maksimum havuzlama ve ortalama havuzlama. Maksimum havuzlama, bir  zellikten en y ksek piksel deđerini alırken, ortalama havuzlama, ilgili b lgedeki piksel deđerlerinin ortalamasını hesaplar. Bu sayede, g r nt  verisi sıkıřtırılırken  nemli bilgiler korunmuř olur (Salomon ve Phelan, 2018). Maksimum havuzlama katmanlarının yapılacak olan  alıřma i in belirli  zelliklerin  ıkarılmasında yardımcı olması i in kullanılmaktadır.




Şekil 3. 2. Maksimum havuzlama katmanı

3.3.3 Normalleştirme Katmanı (Normalization Layer)

Normalleştirme katmanı, derin öğrenme modellerinde performansı artırmak için kullanılan bir yöntemdir. Bu katman, özellikle toplu normalizasyon ile dikkat çekmektedir. Toplu normalizasyon, eğitim sürecini hızlandırarak normalizasyon etkilerinin korunmasını sağlar ve aynı zamanda, modellerin minimum kayıp noktasına daha hızlı ulaşmasına ve büyük toplu boyutlarda yüksek performans göstermesine olanak tanımaktadır (Budak ve ark., 2021). Bu sayede, derin öğrenme modellerinin verimli ve dengeli bir şekilde eğitilmesi desteklenmektedir.

3.3.4 Bırakma Katmanı (Dropout)


Bırakma katmanı, eğitim sırasında aşırı öğrenmeyi önlemek ve modelin genelleme yeteneğini artırmak amacıyla, belirli bir olasılıkla seçili katmandaki nöronların çıktısını sıfırlar ve ağdaki özellik sensörlerinin aşırı bağımlılık oluşturmasını (eş-uyarlanma) engeller (Budak ve ark., 2021). Bırakma tekniği, özellikle tamamen bağlı katmanların düzenlenmesinde oldukça etkilidir. Bu yaklaşım, modelin daha sağlam ve dengeli bir şekilde öğrenmesini sağlar.



Şekil 3. 3. Bırakma katmanı (Srivastava ve ark., 2014)

3.3.5 Düzleştirme Katmanı (Flatten Layer)

(Jeczminek ve Kowalski, 2021) çalışmalarında, oluşturulan katmanların görüntü özelliklerini çıkarmakla görevli olduğunu ve görüntüyü benzersiz bir şekilde temsil etmek için düşük seviyeli karmaşık özelliklerden oluşan bir matris-vektör ürettiğini göstermiştir. Konvolüsyonel ve havuzlama katmanlarından elde edilen çıktıyı sınıflandırmak için bir sınıflandırma ağı gerekli olduğunu fakat sınıflandırmadan önce bu katmanların çıktılarının tek bir vektörde birleştirilmesi gerektiğini belirtmişlerdir. Derin öğrenme mimarilerinde düzleştirme katmanı, çok boyutlu dizileri tek boyutlu bir vektöre dönüştürmek için tasarlanmıştır ve özellikle ESA' da temel bir bileşendir. Son katman olan tam bağlantılı katman, verileri işlemeye hazır hale getirmektedir ve Evrişim ile Havuzlama katmanlarından gelen çok boyutlu değerleri tek boyutlu bir yapıya dönüştürmektedir (Tiraki ve ark., 2024). Önceki katmanlarda işlemler matrisler üzerinden gerçekleştirilirken, bu katmanda tüm işlemler tek boyutlu bir veri yapısı üzerinde yapılmaktadır. Bu dönüşüm, sınıflandırma veya tahmin gibi son aşama işlemler için gerekli veriyi sağlamaktadır.



Şekil 3. 4. Düzleştirme katmanı

3.3.6 Tam Bağlantılı Katmanı (Dense Layer)


Bu katman, geleneksel bir sinir ağı gibi çalışmaktadır ve ESA'daki parametrelerin yaklaşık %90'ını içermektedir (Budak, 2021). Aynı zamanda özel gizli katman olarak adlandırılan bu yapı, sinir ağının verilerini bir vektöre dönüştürerek iletilmesini sağlamaktadır. Bu dönüşüm, sınıflandırma ve tahmin gibi son işlemler için temel bir adım niteliğindedir. ReLU, Sigmoid, Tanh ve Softmax gibi aktivasyon fonksiyonları, çıkışı belirlemek için kullanılmaktadır. Her bir giriş düğümü, çıkıştaki düğümle ilişkilidir ve bu bağlantılar, ağın öğrenme sürecinde önemli bir rol oynamaktadır. Bu yapı, sinir ağının öğrenme ve genelleme yeteneğini geliştirmektedir (Tiraki ve ark., 2024).

3.4 Transfer Öğrenme Modelleri

Bu çalışmada, BT (Bilgisayarlı Tomografi) görüntülerinde akciğer kanseri teşhisi için, önceden eğitilmiş VGG16, ResNet50, Inception-v3 ve DenseNet121 mimarilerine dayalı modeller kullanılmıştır. Önceden eğitilmiş ağlar, bir milyondan fazla görüntüyü içeren ImageNet veri seti üzerinde eğitilmişlerdir. Bu ağlar, görüntüleri klavye, kurşun kalem ve çeşitli hayvanlar gibi 1000 farklı nesne sınıfına ayırma yeteneğine sahiptir. Bu bağlamda, bu ağlar geniş bir yelpazede görüntüleri temsil eden zengin özellikleri öğrenmişlerdir (Al-Areqi ve Konyar, 2022).

3.4.1 VGG16


VGG-16 modeli Oxford Üniversitesi'ndeki Görsel Geometri Grubu (VGG) tarafından geliştirilmiştir ve 13 konvolüsyonel katman ve 3 tam bağlı katman olmak üzere 16 katmanlı bir ESA mimarisinden oluşmaktadır (Simonyan ve Zisserman, 2015). Her bir evrişimli katman, modelin görüntülerdeki karmaşık desenleri öğrenme kapasitesini artırmak için bir düzeltilmiş doğrusal birim (ReLU) aktivasyon fonksiyonu içerirken, çıktı katmanında bir “Softmax” aktivasyon fonksiyonu uygulanmaktadır. VGG16 dahil olmak üzere transfer öğrenmeye yönelik gelişmiş modeller, karmaşık görüntü tabanlı görevlerde uyarlanabilirliklerine ve doğruluklarına katkıda bulunan çok sayıda parametreye sahiptir (Cetin-Kaya ve Kaya, 2024). Genel olarak VGG16 modeli, evrişimli sinir ağı tasarımıyla önemli bir yeri temsil etmektedir.



Şekil 3. 5. VGG16 Mimari (Geek, 2024)

3.4.2 Resnet50

ResNet (Artık Ağ), 2015 yılında He ve arkadaşları tarafından tanıtılan bir sinir ağı türüdür (He ve ark., 2015). Yapılan çalışmada, çok daha derin ağların eğitimi kolaylaştırmak için bir artık öğrenme yaklaşımı önerilmiştir. 34 katmanlı ağdaki her 2 katmanlı blok, 3 katmanlı darboğaz blokları ile değiştirilerek 50 katmanlı bir ResNet elde edilmiştir. Deneysel sonuçlar, 50 katmanlı ResNet modellerinin doğruluk açısından 34 katmanlı modellerden daha iyi performans gösterdiğini ortaya koymaktadır. Ayrıca, derinlik artışına rağmen herhangi bir bozulma sorunu gözlenmemiştir, bu da ağ derinliğinin artırılmasının tüm değerlendirme kriterlerinde önemli doğruluk kazanımlarına yol açtığını göstermektedir.



Şekil 3. 6. ResNet50 Mimarisi (WMC, 2021)

3.4.3 InceptionV3

(Szegedy ve ark., 2016) tarafından önerilen bir modüldür ve inception-v2'den farklıdır. Farklılıklar arasında yalnızca konvolüsyon katmanlarının değil, aynı zamanda yardımcı sınıflandırıcılar olarak toplu normalizasyon ve tam bağlı (FC) katmanların eklenmesi de yer almaktadır. Bu iyileştirmenin bir sonucu olarak, çerçeve Inception-v3 olarak adlandırılmıştır. Yaptıkları çalışmada ILSVRC 2012 sınıflandırmasında tek ürün değerlendirmesi için tahmini olarak (Ioffe ve Szegedy, 2015) tarafından tanımlanan ağ ile Inception-v3 karşılaştırıldığında, sunulan Inception-v3 modeli hesaplama açısından altı kat daha ucuz ve en az beş kat daha az parametre kullanmaktadır.

3.4.4 DenseNet121

DenseNet121, (Huang ve ark., 2016) tarafından tanımlanan DenseNet121 modelinin temel yapısı, her biri birden fazla evrişimli katman içeren tam bağlantılı bloklardan oluşmaktadır ve bu tam bağlantılı bloklar, katmanlar arasında tam bağlantılı bağlantılar kurarak özellik haritalarını doğrudan sonraki katmanlara yayarak daha derin ve daha kapsamlı özellik öğrenimi sağlayıp model parametrelerinin verimliliğini artırmaktadır. DenseNet121, her tam bağlantılı bloktan sonra derinliğini 121 katmana kadar genişleten bir geçiş katmanı ve sınıflandırma için 1000 birimlik tam bağlantılı bir katman içermektedir. Yapılan deneylerde, herhangi bir performans düşüşü veya aşırı uyum belirtisi olmaksızın artan sayıda parametre ile doğrulukta tutarlı bir iyileşme sağlama eğilimi ve modelin büyük, ayrıntılı veri kümelerini verimli bir şekilde işlemesine olanak tanımaktadır.

3.5 Optimizasyon Algoritmaları

Derin öğrenme modelleri bağlamında optimizasyon algoritmaları, eğitim sürecinin yönlendirmesinde ve modelin performansını iyileştirmesinde önemli bir rol almaktadır. Her birinin kendine özgü avantajları ve dezavantajları olan birçok optimize edici tür vardır. Çalışma sırasında çeşitli optimizasyon algoritmaları kullanıldı bunlar Adam, SGD, RMSprop, Adadelta, Adagrad, Adamax ve Nadam'dır. Bu optimizasyon algoritmaları güncelleme kuralları, öğrenme oranları ve momentum terimleri açısından farklılık göstermektedir ve eğitim sürecinin hızını ve istikrarını etkilemektedir.

3.5.1 SGD

Literatürdeki birçok çalışma sırasında Stokastik Gradyan İnişi (SGD) ismi olarak kullanılmaktadır. SGD, her adımda daha küçük veri bölümlerini veya veri gruplarını işleyerek bellek kullanımını en aza indirip hesaplamayı hızlandırmaktadır (Tian ve ark., 2023). Büyük veri kümelerinde, veri kümesinin tamamının belleğe yüklenmesini gerektirmeden optimizasyona izin verdiği için özellikle avantajlı olabilmektedir. Bu, tüm veri kümesinin aynı anda belleğe sığması ihtiyacını ortadan kaldırdığı ve böylece bellek gereksinimlerini önemli ölçüde azalttığı için büyük verilerle çalışan uygulamalar için önemli hale gelmektedir.

3.5.2 Adagrad

AdaGrad, önceki iterasyonlarda elde edilen gradyanlara dayanarak öğrenme oranını dinamik bir şekilde ayarlayan bir optimizasyon algoritması olarak bilinmektedir. AdaGrad, seyrek gradyan sorunlarını çözmek için etkili bir şekilde kullanılabilir (Tian ve ark., 2023). Özellikle seyrek parametreler için daha büyük güncellemeler yaparken, sık kullanılan parametreler için daha küçük güncellemeler gerçekleştirmektedir (Ruder, 2017). Ancak, algoritma artık yeni bilgiler öğrenmeye ihtiyaç duymadığında, ayarların etkisiz şekilde güncellenmesi gibi bir dezavantajı da vardır (Tian ve ark., 2023). Bu yöntemin en önemli avantajlarından biri, öğrenme oranını manuel olarak ayarlama ihtiyacını ortadan kaldırmasıdır.

3.5.3 RMSprop

RMSprop ve Adadelta, Adagrad'ın giderek azalan öğrenme oranları sorununa çözüm getirme amacıyla, aynı dönemlerde bağımsız olarak geliştirilmiştir. RMSprop, öğrenme oranını karesel gradyanların üssel olarak azalan bir ortalamasına bölerek bu sorunu ele alır (Ruder, 2017). Bu yaklaşım, optimizasyon sürecinde öğrenme oranlarının dengeli bir şekilde ayarlanmasını sağlar ve daha etkili bir öğrenme performansı sunmaktadır.

3.5.4 Adam

Adam algoritması, az bellek kullanımı ve birinci dereceden gradyanlara dayanan bir optimizasyon yöntemidir. İsmi "adaptif momentum" kavramından almaktadır. Bu algoritma, AdaGrad ve RMSProp yöntemlerinin güçlü yönlerini birleştirerek geliştirilmiştir (Çoban, 2023). (Kingma ve Ba, 2014), yaptıkları çalışmalarında Adam algoritmasını uygulaması kolay ve bellek gereksinimi düşük bir yöntem olarak tanımlamışlardır. Çalışmalarında, dışbükey problemlerde yakınsama oranına ilişkin analizlerin deneysel olarak doğrulandığını belirtmişlerdir. Ayrıca, Adam'ın makine öğrenimi alanında, dışbükey olmayan birçok optimizasyon problemi için sağlam ve etkili bir çözüm sunduğunu vurgulamışlardır.

3.5.5 Nadam

Bir diğerk mevcut optimizasyon algoritması Nadam'dır. Nadam, Adam algoritması ile Nesterov Accelerated Gradient (NAG) yöntemlerinin birleşiminden oluşmaktadır. Bu algoritmada, NAG'nin özelliklerini Adam algoritmasına entegre etmek için momentum ifadesinde değışiklik yapılır ve bu sayede yeni bir güncelleme kuralı oluşturulmaktadır (Ruder, 2017).

3.5.6 Adagrad

Adagrad, SGD ve Momentum yöntemlerindeki sabit öğrenme katsayısı sorununu çözmek amacıyla geliştirilmiştir (Bejnordi ve ark., 2017). Her adımda farklı bir öğrenme katsayısı kullanarak, öğrenme katsayısını geçmiş gradientlerin karelerinin kümülatif toplamalarının kareköküne bölmektedir (Bejnordi ve ark., 2017).

3.5.7 Adadelat

Adadelat optimizasyon algoritması, AdaGrad'ın öğrenme oranının zamanla sıfıra yaklaşması sorununu iyileştirmek amacıyla geliştirilmiştir. Adadelat, iki temel fikri bir araya getirmektedir; ilk olarak, öğrenme oranını ölçeklendirmek için AdaGrad'dan farklı olarak tüm geçmişı değıl, yalnızca yakın zaman aralığındaki eğimleri dikkate almaktadır, ikinci olarak, tarihsel güncellemeleri biriktiren ve momentum benzeri bir ivme etkisi sağlayan bir bileşen kullanmaktadır (İNT8, 2016). Bu yaklaşımlar, algoritmanın daha dengeli ve etkili bir optimizasyon süreci sunmasını sağlamaktadır.

3.5.8 Adamax

(Kingma ve Ba, 2014) yaptıkları çalışmalarında Adamax, Adam algoritmasının sonsuzluk normuna (L_∞ normu) dayalı bir türevi ve Adam algoritmasının L_2 normundan L_∞ normuna genişletilmiş bir versiyonu olarak tanımlamaktadır. Bu yaklaşım, özellikle büyük boyutlu parametre vektörlerinde daha kararlı, etkili bir optimizasyon süreci sunarak dikkat çekmektedir ve pratik uygulamalarda Adam algoritmasına kıyasla avantajlı durumlar sağlayabilmektedir.

3.6 Metrikler (Metrics)

Metrikler, modellerinin performansını değerlendirmek için kullanılan, etkinliklerine ve doğruluklarına ilişkin farkındalık sağlayan niceliksel önlemlerdir. Yapılan çalışmada akciğer kanseri tespiti bağlamında ölçümler, tıbbi görüntüleme verilerinden akciğer kanseri hastalarının belirlenmesinde öngörücü modellerin performansının değerlendirilmesinde önemli bir rol oynamaktadır.

3.6.1 Karışıklık Matrisi (Confusion Matrix)

Karışıklık matrisi, sınıflandırıcı performansının kullanışlı ve kapsamlı bir gösterimidir. Genellikle, her veri örneğinin herhangi bir zamanda yalnızca bir sınıfa ait olabileceği çok sınıflı, tek etiketli sınıflandırma modellerini değerlendirmek için kullanılmaktadır (Krstinić ve ark., 2020).

Yapılan çalışmada bir karışıklık matrisi, bir modelin sınıflandırma işleminde ne kadar iyi performans gösterdiğine dair bilgiler sağlamaktadır. Gerçek pozitif (DP), modelin akciğer kanseri bireyleri doğru şekilde tanımladığı durumları temsil ederken, gerçek negatif (DN), modelin akciğer kanseri olmayan bireyleri doğru şekilde tanımladığı durumları temsil etmektedir. Yanlış pozitif (YP), gerçek durum akciğer kanseri olmadığında modelin akciğer kanserini yanlış tahmin ettiği durumlara karşılık gelirken, yanlış negatif (YN), gerçek durum akciğer kanseri olduğunda modelin akciğer dışı kanseri yanlış tahmin ettiği durumları temsil etmektedir. Çalışma sırasında kullanılan karışıklık matrisi ile elde edilen sayılar analiz edilerek sınıflandırma modelinin güçlü veya zayıf yönleri değerlendirilebilmektedir. Karışıklık matrisi yaptığımız çalışmada akciğer kanseri tespiti için sınıflandırma modellerinin performansını değerlendirmek için değerli bir araç olarak kullanılmıştır ve tahmin doğruluğu, hata oranlarına kapsamlı bir genel bir bakış sağlamıştır.

3.6.2 F1 Puanı (F1 Score)

F1 puan değerini bulmak için yapılacak işlem kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır (Goutte ve Gaussier, 2005). Yapılan çalışmada F1 puanı, pozitif vakaları (yani gerçek akciğer kanseri hastalarını) doğru bir şekilde tanımlamanın önemini vurgulayarak, akciğer kanseri tespitinde teşhis modellerinin etkinliğini değerlendirmek

için kullanılmaktadır. Performans parametresinin formülü denklem 1'de verilmiştir. F1 puanı kesinlik ve duyarlılık arasında bir denge kurmaktadır, sınıflandırma modelleri için kapsamlı bir değerlendirme ölçütü olarak hizmet etmektedir ve önemli bir fayda sağlamaktadır.

$$F1 \text{ puanı} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (1)$$

3.6.3 Duyarlılık (Recall)

Duyarlılık, olumlu tahmin etmemiz gereken işlemlerin kaçını olumlu tahmin ettiğimizi gösteren bir metriktir, tahminlerin oranını ölçtüğü için özellikle önemlidir (Saito ve Rehmsmeier, 2015). Performans parametresinin formülü denklem 2'de verilmiştir.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (2)$$

3.6.4 Doğruluk (Accuracy)

Çalışmamızda sınıflandırıcının doğruluğu, doğru sınıflandırılan pozitif ve negatiflerin toplamının toplam örnek sayısına oranı alınarak hesaplanmaktadır (Memiş ve ark., 2019). Performans parametresinin formülü denklem 3'te sunulmuştur.

$$\text{Doğruluk} = \frac{DP + DY}{DP + DN + YP + YN} \quad (3)$$

3.6.5 Kesinlik (Precision)

(Saito ve Rehmsmeier, 2015) sınıflandırıcı performansının dengeli veri kümelerinde arttığını, ancak dengesiz veri kümelerinde azaldığını gözlemlemişlerdir. Ayrıca, kesinlik metriğinin, diğer performans ölçütlerine kıyasla farkları daha net bir şekilde ortaya koyduğunu belirtmişlerdir. Bu çalışmada, kesinlik önemli bir performans ölçütü olarak ele alınmış ve değerlendirilmiştir. Performans parametresine ilişkin formül ise Denklem 4'te sunulmuştur. Gerçek pozitif olan tahminlerin, model tarafından yapılan toplam pozitif tahmin sayısına oranını temsil etmektedir. Yapılan çalışmada kesinlik, tahmin edilen pozitif bireyleri (yani tahmin edilen akciğer sınıf bireyleri) gerçekte gerçek pozitif bireyleri (yani gerçek akciğer sınıf bireyleri) olan oranını ölçmektedir. Kesinlik, yaptığımız çalışmada akciğer kanseri tespit modellerinin performansının

değerlendirilmesinde, özellikle de pozitif tahminlerin doğruluğunun değerlendirilmesinde ve yanlış pozitiflerin en aza indirilmesi konusunda değerli bir ölçüm görevi olarak yer almaktadır.

$$Kesinlik = \frac{DP}{DP + YP} \quad (4)$$

3.7 Çalışmada Kullanılan Programlama Dili

Yapılan çalışmada derin öğrenme uygulamalarında geliştirme yaparken içerikteki problemlere çözüm sağlayabilecek nitelikte olan bir dil seçilmiştir. Bu alanda yapılan çok fazla sayıda araştırma ve uygulamaya bakılarak projeyi geliştirirken karşılaşılabilecek bir sorunun çözümü için çok yönlülüğü, kapsamlı kütüphaneleri ve kullanım kolaylığını barındıran açık kaynak kod sağlayan Python programlama dili tercih edilmiştir. Python programlama dilindeki kütüphaneler içerisinde yer alan opencv, numpy, pandas, scikit-learn, matplotlib, tensorflow ve keras, kütüphaneleri kullanılmıştır.

3.8 Veri Büyütme

Etkili derin öğrenme modelleri oluşturmak için, doğrulama hatasının eğitim hatasıyla birlikte azalması gerekmektedir. Veri büyütme, bu hedefe ulaşmada önemli bir yöntemdir. Bu teknik, mevcut veri örneklerine farklı dönüşümler uygulayarak eğitim veri kümesinin boyutunu ve çeşitliliğini yapay olarak artırmaktadır (Shorten & Khoshgoftaar, 2019).

Artırılmış veriler, daha geniş bir veri noktası kümesini temsil ederek eğitim, doğrulama ve gelecekteki test kümeleri arasındaki farkı en aza indirir ve sonuç olarak modelin genelleme yeteneği artar ve sınırlı veri kullanılabilirliği ile aşırı uyum gibi sorunlar giderilmektedir (Shorten & Khoshgoftaar, 2019).

3.9 Kayıp Fonksiyonu (Loss Function)

Makine öğreniminde, eğitim süreci sırasında modelin parametrelerini ayarlamaya yardımcı olmak ve tahminleri ile gerçek değerler arasındaki farkı en aza indirmeye rehberlik etmek için kayıp fonksiyonları kullanılmaktadır (Terven ve ark., 2024). Bu fark veya hata, modelin hatalarından ders almasını sağlayan kayıp fonksiyonuyla

ölçülmektedir. Akciğer kanseri tespitine yönelik olan derin öğrenme modelleri bağlamında, uygun bir kayıp fonksiyonunun seçimi var olan modelin akciğer kanseri hastalarını doğru bir şekilde sınıflandırmak için eğitilmesi açısından önemli olacaktır.



4. MATERYAL VE METOT

Bu bölümde, çalışmada kullanılan veri seti, model mimarisi, hiperparametre seçimi, optimizasyon algoritmaları ve transfer öğrenme yöntemleri detaylandırılmaktadır. Çalışmanın bilimsel geçerliliğini sağlamak adına, deneylerin nasıl gerçekleştirildiği, hangi yöntemlerin kullanıldığı ve nasıl değerlendirildiği ayrıntılı olarak açıklanmıştır.

4.1 Akciğer Görüntü Veri Seti

Kullanılan veri seti, bilgisayarlı tomografi görüntülerinden oluşmaktadır. Görüntüler, modelin gereksinimlerine uygun olarak dcm formatında değil, jpg veya png formatında hazırlanmıştır (Hany, 2020). Çalışmada kullanılan birincil veri seti, Kaggle veri tabanından alınan göğüs tomografisi görüntülerinden oluşmaktadır. İkincil veri seti ise orijinal veri seti üzerinde veri büyütme yöntemleri kullanılarak mevcut görüntülerden türetilmiş daha kapsamlı bir veri seti daha oluşturulmuştur. Bu süreçte yeniden ölçekleme, döndürme, genişlik ve yükseklik kaydırmaları, kesme ve yakınlaştırma dönüşümleri ile yatay çevirme gibi teknikler uygulanmıştır. Bu büyütme teknikleri, önerilen ESA modelinin eğitim ve değerlendirilmesi için gerekli çeşitliliği sağlamayı amaçlamaktadır. Veri seti, eğitim, test ve doğrulama olmak üzere üç ana klasöre ayrılmıştır. Her klasörde farklı göğüs kanseri türlerini temsil eden üç klasör (adenokarsinom, büyük hücreli karsinom, skuamöz hücreli karsinom) ve normal bilgisayarlı tomografi taramalarını içeren bir klasör bulunmaktadır. Normal sınıfında, akciğer tomografisinde herhangi bir tümör bulunmamaktadır. Veri setinin kaynağı ve hasta mahremiyetine ilişkin etik hususlar, tıbbi araştırmalarda geçerli olan yerleşik yönergelere uygun olarak ele alınmıştır.

Veri setinde normal sınıfına ait bilgisayarlı tomografi görüntüsü Şekil 4.1’de, Adenokarsinom Şekil 4.2’de, Büyük hücreli karsinom Şekil 4.3’te ve Skuamöz hücreli karsinom Şekil 4.4’te gösterilmiştir. Tablo 4.1’de düzenlenen veri setinin değerleri gösterilmektedir. Veri seti eğitim ve test sınıfları olarak ayrılarak görüntüler %80 eğitim seti ve %20 test seti oranlarına bölünmüştür. Üzerinde çalışma yaptığımız bir diğer veri seti ise Kaggle üzerinden almış olduğumuz orijinal veri seti üzerinden veri büyütme işlemi yaparak daha çok genişletilmiş veri setidir. Veri setinin içerisindeki görüntü sayıları Tablo 4.2’de gösterilmiştir. Tablo 4.2’de gösterilen veri seti içerisindeki görüntüler %80 eğitim ve %20 test oranında bölünmüştür.

Tablo 4. 1. Kaggle üzerinden alınan veri setinin düzenlenen hali

	Eğitim	Test
Normal	172	43
Adenokarsinom	271	67
Büyük hücreli karsinoma	150	37
Skvamöz hücreli karsinoma	208	52

Tablo 4. 2. Kaggle üzerinden alınan veri seti üzerinde veri büyütme yapılarak genişletilmiş hale getirilen veri seti


	Eğitim	Test
Normal	1000	250
Adenokarsinom	1000	250
Büyük hücreli karsinoma	1000	250
Skvamöz hücreli karsinoma	1000	250




Şekil 4. 1. Normal sınıfa ait akciğer tomografisi



Şekil 4. 2. Adenokarsinom hücreli akciğer tomografisi



Şekil 4. 3. Büyük hücreli karsinoma sahip akciğer tomografisi



Şekil 4. 4. Skuamöz hücreli karsinoma sahip akciğer tomografisi

4.2 ESA Model Mimarisinin Belirlenmesi

Akciğer kanseri tespiti için en uygun derin öğrenme modelini belirlemek amacıyla farklı evrişimli sinir ağı mimarileri üzerinde çalışmalar yapılmıştır. Kaggle platformundan elde edilen akciğer bilgisayarlı tomografi görüntülerini içeren veri seti kullanılmıştır. Veri seti, farklı akciğer kanseri türlerine ait görüntüleri içeren üç ana gruptan oluşmaktadır: adenokarsinom, büyük hücreli karsinom ve skuamöz hücreli karsinom. Bu gruptaki kanserli görüntüler tek bir klasörde birleştirilmiştir. Daha sonra bu klasör, normal BT görüntülerinin bulunduğu ayrı bir klasörle bir araya getirilerek kanserli ve normal kişilere ait ikili sınıflandırma işleminin gerçekleştirilmesi için uygun bir veri seti oluşturulmuştur. Sonuç olarak, veri seti hem kanserli hem de sağlıklı bireylere ait görüntüleri içermektedir. Çeşitli hiperparametrelerin değiştirilmesiyle modelin performansını iyileştirmeye yönelik deneyler gerçekleştirilmiştir. Bu çalışma için kullanıldığımız veri seti; eğitim, doğrulama ve test kümelerine göre düzenlenmiştir. Görüntüler, ImageDataGenerator eğitim

verilerinin çeşitliliğini artırmak için veri artırımını kolaylaştıran TensorFlow'dan alınan sınıf kullanılarak ön işleme tabi tutulmuştur. Büyütme teknikleri arasında yeniden ölçekleme, döndürme, genişlik ve yükseklik kaydırmaları, kesme ve yakınlaştırma dönüşümleri ve yatay çevirme yer almıştır. Bu yaklaşım, modelin görülmeyen verilere genelleme yapma yeteneğini artırmak için kullanılmıştır. ESA mimarilerinde, daha karmaşık özellikleri çıkarmayı kolaylaştırmak amacıyla sonraki katmanlarda genellikle daha fazla sayıda filtre kullanılması tercih edilmektedir (Kaya, 2023). Bu durum göz önünde bulundurularak denemeler yapılmıştır.

4.3 Hiperparametreler ve Seçim Süreci

Yapılan denemelerde kullanılan hiperparametreler Tablo 4.3'de belirtilmiştir.

Tablo 4. 3. Kullanılan hiperparametreler ve kısaltmaları

Hiperparametreler	Arama Aralığı Değerleri
Evrişimli Katman Sayısı(EKS)	5-15
Filtre Sayısı(FS)	16-512
Optimizasyon Algoritması(OA)	Adam, RMSprop
Öğrenme Oranı (ÖO)	0.00001, 0.0001, 0.001
Parti Boyutu(PT)	16,32
Giriş Görüntü Boyutu (GGB)	180,224
Epoch (E)	10-75

- i. **Evrişimli Katman Sayısı (EKS):** Evrişimli katmanlar, modelin görsellerdeki temel özellikleri öğrenmesini sağlayan kritik bir bileşendir. EKS değeri, modelin derinliğini belirler ve katman sayısının artması, daha karmaşık özelliklerin öğrenilmesine olanak tanımaktadır. Ancak, katman sayısının aşırı artması eğitim süresini uzatabilir ve aşırı öğrenme riskini yükseltebilir. Bu çalışmada, EKS değeri 5 ile 15 arasında değiştirilerek en uygun derinlik seviyesi tespit edilmiştir. Katman sayısı az olduğunda yani ortalama olarak 5'ten küçük olduğunda yüzeysel bir model ortaya çıkmakta ve bu tarz modeller genelde öğrenme güclüğü çekmektedir. Akciğer kanser türlerinin sınıflandırılmasında yüzeysel modeller yeterli ve kapsamlı özellik çıkarmakta zorlanmaktadır.

- ii. **Filtre Sayısı (FS):** Filtreler, her bir evrişimli katmanda görüntüdeki belirli özellikleri algılayan ve öğrenme sürecine katkı sağlayan önemli parametrelerdir. Filtre sayısındaki artış, modelin daha fazla özelliği öğrenmesini sağlar bunun yanında çalışma süresinden kaynaklı eğitim süresi uzayabilir. Bu çalışmada, FS değeri 16 ile 512 arasında test edilerek en uygun filtre sayısı belirlenmiştir.
- iii. **Optimizasyon Algoritması (OA):** Optimizasyon algoritması, görüntünün eğitimi sonucunda sınıflandırma katmanında çıkan hata oranında geri yayılım algoritması ile modelin ağırlıklarını güncellemek için kullanılan bir yöntemdir. Adam ve RMSprop optimizasyon algoritmaları, modelin hızla ve doğru bir şekilde öğrenmesini sağlamak için yaygın olarak kullanılmaktadır. Bu çalışmada her iki algoritma da denenmiş ve en iyi sonuç belirlenmiştir.
- iv. **Öğrenme Oranı (ÖO):** Öğrenme oranı, modelin ağırlıklarını güncellerken adımların büyüklüğünü belirleyen parametredir. Yüksek öğrenme oranları, modelin hızlı öğrenmesini sağlasa da genellikle doğru çözümü kaçırmaya yol açabilir. Düşük öğrenme oranları ise daha dikkatli bir şekilde öğrenmeye olanak tanır ancak eğitim süreci daha uzun sürebilir. Çalışmada, öğrenme oranı 0,00001 ile 0,001 arasında değişerek, en uygun değer bulunmuştur.
- v. **Parti Boyutu (PT):** Parti boyutu, her iterasyonda modelin işlediği veri miktarını ifade etmektedir. Parti boyutunun 16 ve 32 arasında denendiği bu çalışmada, her iki değer de modelin doğruluğu üzerindeki etkisi gözlemlenmiştir.
- vi. **Epoch Sayısı (E):** Epoch, tüm eğitim verisinin model tarafından bir kez işlenmesinin tamamlanması olarak tanımlanmaktadır. Daha fazla epoch, modelin daha fazla öğrenmesini sağlar, ancak aşırı öğrenme riskini de artırabilir. Çalışmada, epoch sayısı 10 ile 75 arasında değiştirilerek modelin yeterince öğrenmesini sağlamak hedeflenmiştir.

4.4 Optimizasyon Algoritmaları ve Çoklu Sınıflandırma

Çalışmada, en iyi modeli belirlemek için farklı mimari yapıların ve hiperparametre optimizasyon yöntemlerinin performansları test edilmiştir. İlk aşamada, ikili sınıflandırma işlemi gerçekleştirilmiş ve Adam ve RMSprop optimizasyon algoritmaları kullanılarak sonuçlar elde edilmiştir. Sonrasında, elde edilen en iyi model, çoklu sınıflandırma işlemine adapte edilmiştir. Bu model ile çalıştırılmadan önce orjinal veri seti düzenlenerek çoklu sınıflandırma işlemi ile akciğer kanseri tespiti gerçekleştirilmiştir:

Çoklu sınıflandırma için Adam, SGD, RMSprop, Adadelta, Adagrad, Adamax ve Nadam gibi farklı optimizasyon algoritmaları test edilmiştir. Algoritmanın performansı, kayıp, doğruluk ve karışıklık matrisi gibi metriklerle karşılaştırılmıştır. Ayrıca, veri büyütme yapılarak, veri setindeki akciğer BT görüntülerinin sayısı artırılarak veri seti genişletilmiştir. Veri büyütme teknikleri, modelin genelleme yeteneğini iyileştirmeyi amaçlamakta olup, eğitim verisini dönüştürerek çeşitlendirilmiş ve modelin daha güçlü öğrenmesini sağlamıştır. Bu genişletilmiş veri seti üzerinde, yukarıda bahsedilen optimizasyon algoritmaları ile aynı testler yapılmış ve elde edilen sonuçlar karşılaştırılmıştır. Gerçekleştirilen deneyler, optimizasyon algoritmalarının ve veri büyütme tekniklerinin modellerin genel başarısına nasıl etki ettiğini anlamaya yönelik kapsamlı bir analiz sunmuştur.

4.5 Transfer Öğrenme Yöntemi

Çalışmada, akciğer kanseri tespiti için transfer öğrenme yöntemi kullanılmıştır. Transfer öğrenme, daha önce eğitilmiş derin öğrenme modellerinin özelliklerinin yeni bir görevde kullanılması prensibine dayanmaktadır.

Çalışmanın başlangıcında, Kaggle platformundan elde edilen veri seti içerisinde düzenleme yapılarak dört farklı transfer öğrenme modeli uygulanarak sonuçlar elde edilmiştir. Veri seti, normal akciğer dokusunun yanı sıra adenokarsinom, büyük hücreli karsinom ve skuamöz hücreli karsinom gibi çeşitli akciğer tümör türlerini içeren BT görüntülerini kapsamaktadır. Çalışmanın ilk aşamasında, veri seti VGG16, ResNet50, Inception-v3 ve DenseNet121 modelleriyle eğitilmiş ve her bir model için F1 puanı, duyarlılık ve doğruluk değerleri elde edilmiştir. Bu işlem sonrasında, aynı dört transfer öğrenme modeli (VGG16, ResNet50, Inception-v3 ve DenseNet121) Kaggle'dan alınan orijinal veri seti üzerinde veri büyütme ile elde edilen genişletilmiş yeni veri seti ile beraber bir kez daha çalıştırılmıştır ve her bir model için F1 puanı, duyarlılık ve doğruluk değerleri elde edilmiştir. Her iki aşamada da modellerin performansı kayıp doğruluk grafikleri ve karışıklık matrisi metrikleri görselleştirilmiştir. Kayıp ve doğruluk, modellerin genel başarısını gösterirken, karışıklık matrisi doğru ve yanlış sınıflandırmaları görselleştirerek, her modelin hangi sınıflarda zorluk yaşadığını ortaya koymuştur.

5. BULGULAR VE TARTIŞMA

Bu çalışmada, normal akciğer dokusunun yanı sıra adenokarsinom, büyük hücreli karsinom ve skuamöz hücreli karsinom gibi çeşitli akciğer tümör türlerini içeren ve BT görüntülerini içeren bir veri seti kullanılmıştır. Çalışma sırasında modeller standart bir bilgisayarda Google Colaboratory ortamında çalıştırılmıştır. Çalışmanın başlangıç aşamasında, veri setindeki farklı akciğer kanseri hastalarına ait BT görüntülerini içeren klasörler birleştirilmiş ve normal hastalara ait görüntülerle birlikte ikili sınıflandırma yapılmıştır. Çeşitli ESA mimarileri ve hiperparametreleri deneyerek akciğer kanserinin kesin tespiti için en yüksek doğruluk veren modeli bulmak hedeflenmiştir. Çalışmanın sonuçlarına ilişkin bulgular Tablo 5.1 içerisinde gösterilmiştir.

Tablo 5. 1. Yapılan deneysel çalışmalar

Model No	EKS	FS	GG B	E	P T	OA	DO	F1	ÖÖ
1	7	32,32,64,64,128,128,512	224	10	16	RMSprop	87	85	0,0001
2	9	16,16,32,32,64,64,128,128,512	224	15	16	Adam	85	86	0,001
3	7	32,32,64,64,128,128,256,256,512	224	50	16	RMSprop	93	90	0,0001
4	7	32,32,64,64,128,128,512	224	15	32	Adam	80	71	0,001
5	7	32,32,64,64,128,128,512	224	10	16	Adam	80	82	0,001
6	9	32,32,64,64,128,128,256,256,512	224	30	16	Adam	67	65	0,00001
7	6	32,32,64,64,128,256	224	40	16	RMSprop	88	78	0,001
8	11	32,32,32,64,64,64,64,128,128,256,512	224	70	32	RMSprop	72	72	0,001
9	7	32,32,64,64,128,128,512	224	30	32	Adam	90	91	0,0001
10	8	32,32,64,64,128,128,256,512	224	35	32	RMSprop	65	64	0,001
11	11	32,32,32,64,64,64,64,128,128,256,512	224	25	32	RMSprop	80	71	0,0001
12	9	16,16,32,32,64,64,128,128,512	224	40	32	Adam	80	72	0,001
13	10	16,16,32,32,64,64,128,128,128,512	180	20	32	Adam	86	84	0,0001
14	9	16,16,32,32,64,64,128,128,512	180	40	32	Adam	70	82	0,001
15	7	32,32,64,64,128,128,512	224	10	32	Adam	53	48	0,001
16	8	16,16,32,32,64,64,128,512	180	50	32	Adam	80	71	0,001
17	7	32,32,64,64,128,128,512	180	20	16	RMSprop	64	66	0,001
18	10	16,16,32,32,64,64,128,128,128,512	224	25	32	RMSprop	77	78	0,0001
19	6	32,32,64,64,128,256	180	40	16	Adam	65	67	0,001
20	7	32,32,64,64,128,128,512	180	50	16	RMSprop	73	75	0,0001
DO: Doğruluk Oranı, F1: F1 Puanı									


Yapılan deneyler karşılaştırıldığında en iyi sonucu veren Tablo 5.1’de gösterildiği gibi %93 doğruluk ve %90 F1 puanı elde edilen model olmuştur. Model eğitimi sırasında 0.0001’lik bir öğrenme oranı kullanılarak, 16’lık bir parti boyutu ve 50 epoch boyunca çalıştırılmıştır. Kullanılan Evrişimli Sinir Ağı mimarisi TensorFlow ve Keras kullanılarak uygulanmıştır.

- i. **Evrişim Katmanları:** Her bir evrişim katmanı, öğrenme sürecini stabilize etmek için ReLU aktivasyonu ile 3x3 filtre kullanıldı ve ardından Toplu Normalizasyon uygulandı.
- ii. **Havuzlama Katmanları:** Özellik haritalarının mekansal boyutlarını azaltmak için her bir evrişimli bloktan sonra 2x2 filtreli MaxPooling katmanları uygulandı.
- iii. **Normalleştirme Katmanı:** Normalleştirme katmanları, bir katman içindeki nöronların aktivasyonlarını normalleştirerek benzer olarak ölçek ve dağılımlar sergilemelerini sağlamaktadır (Ba ve ark., 2016).
- iv. **Bırakma Katmanı:** Sinir ağlarında kullanılan bırakma katmanları, her eğitim yinelemesi sırasında nöronların bir kısmını rastgele devre dışı bırakarak ağı aşırı uyum (overfitting) riskini azaltmaya zorlamaktadır ve belirli nöronlara olan bağımlılığı azaltmaktadır. (Gal ve Ghahramani 2016).
- v. **Düzleştirme Katmanı:** Çok boyutlu dizileri tek boyutlu bir vektöre dönüştürmek için tasarlanmıştır ve özellikle evrişimli sinir ağlarında temel bir bileşendir.
- vi. **Tam Bağlı Katmanı:** Özellik haritaları düzleştirildikten sonra 512 birim ve ReLU aktivasyonu içeren tam bağlı bir katman eklenmiştir.
- vii. **Çıktı Katmanı:** Çıktı katmanı, iki klasör bulunan veri seti için iki sınıfa karşılık gelen 1 nöronlu sigmoid aktivasyonu kullanılarak çalıştırılmıştır. Diğer çalışmalar sırasında bulunan veri setine uygun olarak dört sınıfa karşılık gelen softmax aktivasyonu kullanılarak çalıştırılmıştır.

En iyi performansı gösteren ESA derin öğrenme mimarisi ile gerçekleştirilen akciğer görüntülerinin eğitim katmanları Tablo 5.2’de gösterilmiştir. Önerilen ESA mimarisi Şekil 5.1’de görsel bir şekilde sunulmuştur.

Tablo 5. 2. ESA Mimarisi: Katman Özellikleri ve Parametre Sayısı

Layer (type)	Output Shape	Param #
conv2d	(None, 224, 224, 32)	896
batch_normalization	(None, 224, 224, 32)	128
max_pooling2d	(None, 112, 112, 32)	0
conv2d_1	(None, 112, 112, 32)	9248
batch_normalization_1	(None, 112, 112, 32)	128
max_pooling2d_1	(None, 56, 56, 32)	0
conv2d_2	(None, 56, 56, 64)	18496
batch_normalization_2	(None, 56, 56, 64)	256
conv2d_3	(None, 56, 56, 64)	36928
batch_normalization_3	(None, 56, 56, 64)	256
max_pooling2d_2	(None, 28, 28, 64)	0
conv2d_4	(None, 28, 28, 128)	73856
batch_normalization_4	(None, 28, 28, 128)	512
conv2d_5	(None, 28, 28, 128)	147584
batch_normalization_5	(None, 28, 28, 128)	512
max_pooling2d_3	(None, 14, 14, 128)	0
conv2d_6	(None, 14, 14, 256)	295168
batch_normalization_6	(None, 14, 14, 256)	1024
conv2d_7	(None, 14, 14, 256)	590080
batch_normalization_7	(None, 14, 14, 256)	1024
max_pooling2d_4	(None, 7, 7, 256)	0
Flatten	(None, 12544)	0
Dense	(None, 512)	6423040
dropout	(None, 512)	0
dense_1	(None, 4)	2052
Total params:		7601188 (29.00 MB)
Trainable params:		7599268 (28.99 MB)
Non-trainable params:		1920 (7.50 KB)

**Şekil 5. 1.** Önerilen evrişimli sinir ağı mimarisi

Veri seti eski haline getirilip düzenleme yapılarak çoklu sınıflandırma işlemi gerçekleştirilmiştir. Bu aşamada, optimizasyon algoritmalarının performansları karşılaştırılmış ve Adam, SGD, RMSprop, Adadelta, Adagrad, Adamax ve Nadam dahil olmak üzere çeşitli optimizasyon algoritmaları kullanılarak optimizasyon algoritmaları arasında karşılaştırma yapılmıştır. Modelin performansı, doğruluk, kesinlik, duyarlılık, F1 puanı kullanılarak test setinde değerlendirilmiştir ve bu ölçümler, modelin akciğer kanseri görüntülerini doğru şekilde sınıflandırma yeteneğinin kapsamlı bir değerlendirmesini bizlere sağlamıştır. Tablo 5.3’de elde edilen değerler gösterilmiştir.


Tablo 5. 3. Kaggle üzerinden alınan veri seti ile farklı optimizasyon algoritmaları kullanılarak elde edilen sonuçlar (orijinal veri seti)

Optimizasyon Algoritması	Doğruluk	F1 Puan	Duyarlılık	Kesinlik
Adam	87	87	87	88
SGD	63	61	61	61
RMSprop	73	71	72	69
Adadelta	78	76	76	77
Adagrad	60	63	63	63
Adamax	74	74	74	73
Nadam	62	58	61	57

En iyi değeri veren Adam optimizasyon algoritmasının sonuçları Tablo 5.4’de gösterilmiştir. Şekil 5.4’te optimizasyon algoritmalarından Adam ile elde edilen karmaşıklık matrisi gösterimi gösterilmiştir. Çalışmada eğitim süreci, epoch süresi boyunca doğruluğu ve kayıpları grafik olarak görselleştirilmiştir ve Şekil 5.2’de Adam doğruluk grafiği, Şekil 5.3’te Adam için kayıp grafiği gösterilmiştir. Bu grafikler, modelin öğrenme davranışının anlaşılmasına ve aşırı uyum sorunlarının belirlenmesine yardımcı olmuştur. Yapılan çalışmada optimizasyon algoritmaları arasından en iyi sonucu veren Adam olmuştur. Doğruluk oranı %87 ve F1 puanı %87 olarak elde edilmiştir.


Tablo 5. 4. Adam optimizasyon algoritması kullanılarak elde edilen sonuçlar (orijinal veri seti)

	Kesinlik	Duyarlılık	F1-Puanı
adenocarcinoma	0.91	0.76	0.83
largecellcarcinoma	0.91	0.78	0.84
Normal	0.93	1.00	0.97
squamouscellcarcinoma	0.77	0.96	0.85
accuracy	-	-	0.87
macro avg	0.88	0.88	0.87




Şekil 5. 2. Adam doğruluk grafiği

Şekil 5.2’de gösterilen Adam doğruluk grafiği gözlemlendiğinde, eğitim süreci boyunca modelin öğrenme ilerlemesini göstermektedir Eğitim doğruluğu, epoch sayısının artışıyla birlikte tutarlı bir şekilde yükselmekte ve modelin eğitim veri setinden etkili bir şekilde öğrendiğini açıkça ortaya koymaktadır. Benzer şekilde, doğrulama doğruluğu da benzer bir yukarı doğru eğilim izlemiştir. Ancak, doğrulama doğruluğunda özellikle 50. epochtan sonra dalgalanmalar meydana gelmiştir. Bu durum, modelin eğitim verilerine aşırı uyum sağlaması nedeniyle doğrulama kümesindeki performans tutarlılığını olumsuz etkileyebilecek olası bir aşırı uyumun göstergesi olarak gözükebilir. Ancak, eğitim ve doğrulama doğruluğu arasındaki farkın nispeten küçük olması ve sonlara doğru tekrar farkın azalması, modelin ciddi bir aşırı uyum sorunu yaşamadığını göstermektedir.



Şekil 5. 3. Adam için kayıp grafiği

Şekil 5.3'te Adam için kayıp grafiği gösterilmiştir. Hem eğitim hem de doğrulama kayıplarının epoch sayısı arttıkça düzenli bir şekilde değeri azalmaktadır. Eğitimin başlangıç aşamalarında, eğitim ve doğrulama kayıplarının uyum içinde olması, modelin başlangıçta iyi bir genelleme yeteneğine sahip olduğunu işaret etmektedir. Ancak, sonlara doğru doğrulama kaybında, düzensiz dalgalanmalar gözlemlenmiştir. Eğitim ve doğrulama kayıpları arasındaki bu farklılık, modelin eğitim verilerine giderek daha iyi uyum sağlarken, doğrulama verilerinde aynı performansı gösterememesi nedeniyle aşırı uyum belirtisi olarak değerlendirilmektedir. Ancak, eğitim ve doğrulama kayıpları arasındaki farkın nispeten küçük olması ve sonlara doğru düzelmesi ile modelin ciddi bir aşırı uyum sorunu yaşamadığını göstermektedir.



Şekil 5. 4. Adam karmaşıklık matrisi gösterimi

Şekil 5.4'te optimizasyon algoritmalarından Adam ile elde edilen karmaşıklık matrisi gösterimi gösterilmiştir. Karmaşıklık matrisi, modelin her sınıfa özgü performansını detaylı bir şekilde ortaya koymaktadır. Diyagonal boyunca güçlü bir baskınlık görülmesi, modelin çoğu örneği doğru bir şekilde sınıflandırdığını ifade etmektedir. Özellikle normal sınıf, yanlış sınıflandırma olmaksızın mükemmel bir şekilde ayrılmış olup, modelin bu sınıfı diğerlerinden başarıyla ayırt edebildiğini göstermektedir.

Gerçekleştirilen çalışmadan sonra Kaggle üzerinden aldığımız orijinal veri seti ile veri büyütme işlemi yapılarak, mevcut veri örneklerine farklı dönüşümler uygulanmıştır. Bu işlem modellerinin genelleme performansını artırarak, sınırlı veri kullanılabilirliği, aşırı

uyum gibi zorlukların giderilmesine yardımcı olmak için kullanılmıştır (Shorten & Khoshgoftaar, 2019). Veri büyütme sırasında döndürme, yeniden ölçekleme, genişlik ve yükseklik kaydırmaları, kesme ve yakınlaştırma dönüşümleri ve yatay çevirme yer aldı. Bu işlemten sonra en iyi sonucu veren mimari ile Adam, SGD, RMSprop, Adadelata, Adagrad, Adamax ve Nadam optimizasyon algoritmaları kullanılarak optimizasyon algoritmaları arasında karşılaştırma işlemi yapılmıştır. Modelin performansı, doğruluk, kesinlik, duyarlılık, F1 puanı kullanılarak test setinde değerlendirilmiştir. Tablo 5.5’de elde edilen değerler gösterilmiştir.


Tablo 5. 5. Kaggle üzerinden aldığımız orijinal veri seti ile veri büyütme yapılarak genişletilmiş veri seti kullanılarak farklı optimizasyon algoritmalar ile elde edilen sonuçlar

Optimizasyon Algoritması	Doğruluk	F1 Puan	Duyarlılık	Kesinlik
Adam	75	75	76	74
SGD	74	73	74	71
RMSprop	96	95	96	96
Adadelata	86	86	86	87
Adagrad	63	64	63	65
Adamax	90	90	90	91
Nadam	62	65	62	67

En iyi değeri veren RMSprop optimizasyon algoritmasının sonuçları Tablo 5.6’da gösterilmiştir. Şekil 5.7’de optimizasyon algoritmalarından RMSprop ile elde edilen karmaşıklık matrisi gösterimi gösterilmiştir. Çalışmada eğitim süreci, epoch süresi boyunca doğruluğu ve kayıpları grafik olarak görselleştirilmiştir ve Şekil 5.5’de RMSprop doğruluk grafiği, Şekil 5.6’da RMSprop için kayıp grafiği gösterilmiştir. Yapılan çalışmada optimizasyon algoritmaları arasından en iyi sonucu veren RMSprop olmuştur. Doğruluk oranı %96 ve F1 puanı %95 olarak elde edilmiştir.


Tablo 5. 6. RMSprop optimizasyon algoritması kullanılarak elde edilen sonuçlar(genişletilmiş veri seti)

	Kesinlik	Duyarlılık	F1-Puanı
adenocarcinoma	0.91	0.94	0.92
largecellcarcinoma	0.96	0.97	0.97
normal	0.98	1.00	0.99
squamouscellcarcinoma	0.97	0.91	0.94
accuracy	-	-	0.95
macro avg	0.96	0.95	0.95




Şekil 5. 5. RMSprop için doğruluk grafiği

Şekil 5.5’de RMSprop doğruluk grafiği gösterilmiştir. Eğitim doğruluğu, düzenli bir şekilde artarak yüksek seviyelerde kalırken, doğrulama doğruluğu başlangıçtaki artışın ardından dalgalanmalar göstermektedir. Bu durum, modelin eğitim verilerinde başarılı bir şekilde öğrenme gerçekleştirdiğini, ancak doğrulama verilerine genelleme yapma konusunda tutarlılık sağlayamadığını göstermektedir ancak sonlara doğru dalgalanmanın azaldığını ve bu sorunun üstesinden gelindiğini görmekteyiz.



Şekil 5. 6. RMSprop için kayıp grafiği

Şekil 5.6’da RMSprop için kayıp grafiği gösterilmiştir. Eğitim ve doğrulama kayıplarının epoch boyunca azalması, modelin başarılı bir şekilde öğrenme gerçekleştirdiğini göstermektedir. Ancak, doğrulama kaybının eğitim kaybına kıyasla belirgin dalgalanmalar sergilemesi, modelin doğrulama kümesi üzerinde genelleme yapma konusunda tutarsızlık yaşadığını düşündürmektedir. Ancak, sonlara doğru dalgalanmanın azaldığını ve bu sorunun üstesinden geldiğini görmekteyiz.




Şekil 5. 7. RMSprop karmaşıklık matrisi gösterimi

Şekil 5.7’de optimizasyon algoritmalarından RMSprop ile elde edilen karmaşıklık matrisi gösterilmiştir. Karmaşıklık matrisi, modelin genel olarak iyi performans gösterdiğini, tahminlerin çoğunun diyagonal boyunca doğru sınıflandırmalar yaptığını göstermiştir. Veri集中的 görüntü sayıları göz önünde bulundurulduğunda genel olarak çok iyi bir sınıflandırma ortaya çıkmıştır. Kaggle’den alınan veri setinin orijinal hali üzerinde düzenlenen veri seti ile VGG16, Resnet50, InceptionV3, DenseNet121 transfer öğrenmeleri kullanılarak elde edilen sonuçlar Tablo 5.7’de gösterilmiştir.

Tablo 5. 7. Kaggle üzerinden alınan veri seti içerisinde düzenleme yapılan seti ile transfer öğrenme kullanılarak elde edilen sonuçlar (orijinal veri seti)


Model	F1 Puan	Duyarlılık	Doğruluk
VGG16	65	67	67
Resnet50	78	78	78
InceptionV3	60	60	61
DenseNet121	74	74	76

Elde edilen sonuçlara bakıldığı zaman veri setimiz için en yüksek doğruluğa ulaşan transfer öğrenme Resnet50 olmuştur ve %78 doğruluğa ulaşmıştır. Şekil 5.10'da transfer öğrenmelerden Resnet50 ile elde edilen karmaşıklık matrisi gösterimi gösterilmiştir. Şekil 5.8'de Resnet50 doğruluk grafiği, Şekil 5.9'da Resnet50 için kayıp grafiği gösterilmiştir.




Şekil 5. 8. ResNet50 için doğruluk grafiği

Şekil 5.8'de Resnet50 doğruluk grafiği gözlemlendiğinde başlarda eğitim ve doğrulama arasında biraz dalgalanmalar var olsa da eğitim doğruluğu ve doğrulama doğruluğu da epoch sayısı ile birlikte istikrarlı bir şekilde artmaktadır ve dalgalanmalar azalarak yukarıya doğru artmaya devam etmektedir. Doğruluk grafiği gözlemlendiğinde, modelin eğitim verilerinde başarılı bir şekilde öğrenme gerçekleştirdiğini görmekteyiz.



Şekil 5. 9. ResNet50 için kayıp grafiği

Şekil 5.9’da Resnet50 için kayıp grafiği gösterilmiştir. Kaybın, başlangıçta yüksek olduğunu ve dalgalanmalar oluştuğunu görmekteyiz. Ancak epoch sayısı arttıkça zamanla hızla düştüğünü ve dalgalanmanın bittiğini görmekteyiz. Eğitim ve doğrulama kayıplarının epoch boyunca azalması, modelin başarılı bir şekilde öğrenme gerçekleştirdiğini göstermektedir.



Şekil 5. 10. ResNet50 karmaşıklık matrisi gösterimi


Şekil 5.10’da transfer öğrenmelerden Resnet50 ile elde edilen karmaşıklık matrisi gösterimi gösterilmiştir. Karmaşıklık matrisi gözlemlediğimizde diyagonal boyunca güçlü bir baskınlık görülmektedir. Modelin normal sınıflar için yüksek doğruluk sergilemiştir.

Kaggle üzerinden alınan veri seti görüntüleri ile veri büyütmesi yapılarak elde ettiğimiz genişletilmiş veri seti için transfer öğrenme kullanılarak elde edilen sonuçlar Tablo 5.8’de gösterilmiştir.

Tablo 5. 8. Kaggle üzerinden aldığımız orijinal veri seti üzerinde veri büyütme yapılarak genişletilmiş veri seti ile transfer öğrenme kullanılarak elde edilen sonuçlar


Model	F1 Puan	Duyarlılık	Doğruluk
VGG16	64	67	65
Resnet50	56	57	57
InceptionV3	61	61	60
DenseNet121	86	86	86

Elde edilen sonuçlara bakıldığı zaman veri büyütmesi ile elde ettiğimiz veri setimiz için en yüksek doğruluğa ulaşan transfer öğrenme modelimiz DenseNet121 olmuştur ve %86 doğruluğa ulaşmıştır. Şekil 5.13'te transfer öğrenmelerden DenseNet121 ile elde edilen karmaşıklık matrisi gösterimi gösterilmiştir. Şekil 5.11'de DenseNet121 doğruluk grafiği, Şekil 5.12'da DenseNet121 için kayıp grafiği gösterilmiştir.




Şekil 5. 11. DenseNet121 için doğruluk grafiği

Şekil 5.11'de DenseNet121 doğruluk grafiği gösterilmiştir. Eğitim doğruluğu düzenli bir şekilde artarak yüksek seviyelerde kalırken, doğrulama doğruluğu dalgalanmalar göstermektedir. Bu durum, modelin eğitim verilerinde başarılı bir şekilde öğrenme gerçekleştirdiğini, ancak doğrulama verilerine genelleme yapma konusunda tutarlılık sağlayamadığını göstermektedir ancak sonlara doğru dalgalanmanın azaldığını ve bu sorunun üstesinden gelindiğini görmekteyiz.



Şekil 5. 12. DenseNet121 için kayıp grafiği

Şekil 5.12’da DenseNet121 için kayıp grafiği gösterilmiştir. Kaybın başlangıçta yüksek olduğunu giderek değerin azaldığını ve çok fazla fark olmadan doğrulama kaybında dalgalanmalar oluştuğunu görmekteyiz. Ancak sonlara doğru dalgalanmanın genel olarak azaldığını görmekteyiz. Eğitim ve doğrulama kayıplarının epoch boyunca azalması, modelin başarılı bir şekilde öğrenme gerçekleştirdiğini göstermektedir.



Şekil 5. 13. DenseNet121 için karmaşıklık matrisi gösterimi

Şekil 5.13’te transfer öğrenmelerden DenseNet121 ile elde edilen karmaşıklık matrisi gösterimi gösterilmiştir. Karmaşıklık matrisi gözlemlediğimizde diyagonal boyunca güçlü bir baskınlık görülmektedir. Bu sonuçlar değerlendirildiği zaman, modelin normal ve büyük hücreli karsinom sınıflarında yüksek bir doğruluk gösterdiğini görüyoruz.

6. SONUÇ VE ÖNERİLER

Akciğer kanseri, dünya çapında en yüksek ölüm oranlarına sahip en ölümcül kanser türlerinden biridir. Akciğer kanserinin erken teşhisi, zamanında ve etkili tedavinin başlatılması için çok önemlidir. Akciğer kanseri genellikle uzman klinisyenler tarafından BT görüntülerinin değerlendirilmesi ve biyopsi ile doğrulanması yoluyla teşhis edilir. Ancak BT görüntülerinin yorumlanması klinisyenler arasında farklılık gösterebilir ve değerlendirme süreci sırasında zaman zaman insan hataları meydana gelebilir. Bu nedenle, akciğer rahatsızlıklarını doğrudan görüntülerden teşhis edebilen yapay zekâ sistemleri geliştirmek büyük önem taşımaktadır. Bu çalışmada, BT görüntülerinden akciğer kanserlerini yüksek doğrulukla sınıflandırmak için tasarlanmış bir mimari öneriyoruz.

ESA modellerini temel alarak, orijinal veri seti üzerinde düzenleme yapılarak oluşturulan veri seti ile veri büyütme yoluyla oluşturulan genişletilmiş bir veri seti arasında bir karşılaştırma yaptık ve çeşitli optimizasyon algoritmaları kullandık. Deneyler herkese açık bir Kaggle veri seti kullanılarak gerçekleştirildi ve farklı optimizasyon algoritmalarıyla elde edilen sonuçlar analiz edildi. Düzenlenen veri seti üzerinde yapılan deneylerde Adam algoritması 100 epoch boyunca çalıştırılarak %87 doğruluk oranına ve %87 F1 puanına ulaştı. Veri büyütme yapılarak oluşturulan genişletilmiş veri setinde yapılan deneylerde RMSprop algoritması 25 epoch boyunca çalıştırılarak önemli ölçüde iyileştirilmiş bir performans gösterdi, %96 doğruluk oranına ve %95 F1 puanına ulaştı. İki deney karşılaştırıldığında veri büyütme yapılarak genişletilmiş veri seti daha hızlı ve daha yüksek bir doğruluğa ulaştı.

Orijinal veri seti üzerinde düzenleme yapılan veri seti ile transfer öğrenme kullanılarak yapılan deneylerde ise Resnet50 mimarisi 100 epoch boyunca çalıştırılarak, %78 doğruluk oranı ve %78 F1 puanı elde etti. Veri büyütme yapılarak oluşturulan genişletilmiş veri seti üzerinde transfer öğrenme kullanılarak yapılan deneylerde DenseNet121 mimarisi kullanılarak 25 epoch boyunca çalıştırılarak %86'lık bir doğruluk oranı ve %86'lık bir F1 puanı elde etti. İki deney karşılaştırıldığında veri büyütme yapılarak genişletilmiş veri setinin transfer öğrenme kullanılarak yapılan çalışmalar üzerinde daha hızlı ve daha yüksek bir doğruluğa ulaştı. Bu yüksek lisans tezi, BT tarama görüntülerini sınıflandırarak akciğer kanserinin erken teşhisinde doktorlara yardımcı olmak üzere tasarlanmış ESA tabanlı bir karar destek sistemi sunmaktadır. Yapılan

alıřmalar sonucunda nerilen mimarinin etkililięini gstermekte ve akcięer kanseri sınıflandırma modellerinin performansını artırmada optimizasyon algoritmalarının nemi ve veri bytmenin nemini vurgulamaktadır. nerilen sistem, kanserli dokuları tanımlamayı ve yerini tespit etmeyi amalayan gelecekteki alıřmalar iin bir temel grevi grebilir. Daha fazla geliřtirmeyle, bu sistem yalnızca kanserli dokuları tespit etmekle kalmayıp aynı zamanda boyut ve hacim gibi tmre zg nitel zellikler de saęlayabilen bir Bilgisayar Destekli Tanı (CAD) ara yzne geniřletilebilir.



7. KAYNAKÇA

- ACS, The American Cancer Society medical and editorial content team. (2024). What Is Lung Cancer? About Lung Cancer.
- Akila Agnes, S., Alex Pandian S., I., Anitha, J., & Solomon. A Arun. (2021). Classification of Lung nodules using Convolutional long short-term Neural Network. Proceedings - 5th International Conference on Computing Methodologies and Communication, ICCMC 2021, 1349–1353. <https://doi.org/10.1109/ICCMC51019.2021.9418319>
- Akın, E., & Şahin, M. E. (2024). Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. EMO Bilimsel Dergi, 14(1), 27–38. <https://dergipark.org.tr/tr/pub/emobd/issue/83029/1338066>
- Alakwaa, W., Nassef, M., & Badr, A. (2017). Lung Cancer Detection and Classification with 3D Convolutional Neural Network (3D-CNN). International Journal of Advanced Computer Science and Applications, 8(8), 66–73. <https://doi.org/10.14569/IJACSA.2017.080853>
- Al-Areqi, F., & Zeki Konyar, (2022). Transfer Öğrenme Mimarileri Kullanılarak Bilgisayarlı Tomografi Görüntülerinden Covid-19'un Yüksek Doğrulukla Sınıflandırılması. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 13(3), 457–466. <https://doi.org/10.24012/DUMF.1129870>
- Alsaif, H., Guesmi, R., Alshammari, B. M., Hamrouni, T., Guesmi, T., Alzamil, A., & Belguesmi, L. (2022). A novel data augmentation-based brain tumor detection using convolutional neural network. Applied Sciences, 12(8), 3773. <https://doi.org/10.3390/app12083773>
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. IEEE Transactions on Medical Imaging, 35(5), 1207–1216. <https://doi.org/10.1109/TMI.2016.2535865>
- Ashhar, S. M., Mokri, S. S., Rahni, A. A. A., Huddin, A. B., Zulkarnain, N., Azmi, N. A., & Mahaletchumy, T. (2021). Comparison of deep learning convolutional neural network (CNN) architectures for CT lung cancer classification. International Journal of Advanced Technology and Engineering Exploration, 8(74), 126–134. <https://doi.org/10.19101/IJATEE.2020.S1762126>
- ASM, (2024). Akciğer Kanseri Belirtileri Nelerdir? Nedenleri ve Tedavisi | Anadolu Sağlık Merkezi Hastanesi. <https://www.anadolusaglik.org/saglik-rehberi/akciger-kanseri>
- Ba, J. L., Kiros, J. R., & Hinton, G. E. (2016). Layer Normalization. <https://arxiv.org/abs/1607.06450v1>
- Bejnordi, B. E., Veta, M., Van Diest, P. J., Van Ginneken, B., Karssemeijer, N., Litjens, G., Van Der Laak, J. A. W. M., Hermesen, M., Manson, Q. F., Balkenhol, M., Geessink, O., Stathonikos, N., Van Dijk, M. C. R. F., Bult, P., Beca, F., Beck, A. H., Wang, D., Khosla, A., Gargeya, R., ... Venâncio, R. (2017). Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer. JAMA, 318(22), 2199–2210. <https://doi.org/10.1001/JAMA.2017.14585>
- Benbakreti, S., Benouis, M., Roumane, A., & Benbakreti, S. (2023). Impact of the data augmentation on the detection of brain tumor from MRI images based on CNN and pretrained models. Multimedia Tools and Applications, 83(13), 39459–39478. <https://doi.org/10.1007/s11042-023-17092-0>
- Budak, C., Mençik, V., & Asker, M. E. (2021). Effect on model performance of regularization methods. DUJE (Dicle University Journal of Engineering), 12, 757–765. <https://doi.org/10.24012/dumf.1051352>
- Claro, M. L., Veras, R. D. M. S., Santana, A. M., Vogado, L. H. S., Braz Junior, G., Medeiros,

- F. N. S. D., & Tavares, J. M. R. S. (2022). Assessing the impact of data augmentation and a combination of CNNs on leukemia classification. *Information Sciences*, 609, 1010–1029. <https://doi.org/10.1016/j.ins.2022.07.059>
- Cuşkun, Y., Kaplan, K., Alparslan, B., & Ertunç, H. M. (2023). Classification of the brain metastases based on a new 3D deep learning architecture. *Soft Computing*, 27(22), 17243–17256. <https://doi.org/10.1007/s00500-023-08051-w>.
- Çetin-Kaya, Y., & Kaya, M. (2024). A Novel Ensemble Framework for Multi-Classification of Brain Tumors Using Magnetic Resonance Imaging. *Diagnostics* 2024, Vol. 14, Page 383, 14(4), 383. <https://doi.org/10.3390/DIAGNOSTICS14040383>
- Çoban, S. (2023). Akciğer Kanseri Tanısında Yapay Zeka Yöntemlerinin Karşılaştırılması. *ONDOKUZ MAYIS ÜNİVERSİTESİ*.
- Gal, Y., & Ghahramani, Z. (2015). Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning. 33rd International Conference on Machine Learning, ICML 2016, 3, 1651–1660. <https://arxiv.org/abs/1506.02142v6>
- Geek. (2024, March 21). VGG-16 CNN model GeeksforGeeks. <https://www.geeksforgeeks.org/vgg-16-cnn-model/>
- Goutte, C., & Gaussier, E. (2005). A Probabilistic Interpretation of Precision, Recall and F-Score, with Implication for Evaluation. *Lecture Notes in Computer Science*, 3408, 345–359. https://doi.org/10.1007/978-3-540-31865-1_25
- Hany, M. (2020). Chest CT-Scan images Dataset. Kaggle. <https://www.kaggle.com/datasets/mohamedhanyyy/chest-ctscan-images>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-December, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2018). DenseNet:Densely Connected Convolutional Networks arXiv:1608.06993v5. *Arxiv*, 28(4), 362–371. <https://github.com/liuzhuang13/DenseNet>.
- INT8. (2016, January 6). Optimization techniques comparison in Julia: SGD, Momentum, Adagrad, Adadelata, Adam. *Int8.Io*. <https://int8.io/comparison-of-optimization-techniques-stochastic-gradient-descent-momentum-adagrad-and-adadelata/>
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. 32nd International Conference on Machine Learning, ICML 2015, 1, 448–456. <https://arxiv.org/abs/1502.03167v3>
- Jeczminek, E., & Kowalski, P. A. (2021). Flattening layer pruning in convolutional neural networks. *Symmetry*, 13(7). <https://doi.org/10.3390/sym13071147>
- Karaca, Y. E. (2023). Akciğer Kanserinin Bilgisayarlı Tomografi Görüntüleri Kullanılarak Derin Öğrenme ile Tespiti. In *Malatya Turgut Özal Üniversitesi Lisansüstü Eğitim Enstitüsü*.
- Karim, D. Z., & Bushra, T. A. (2021). Detecting Lung Cancer from Histopathological Images using Convolution Neural Network. *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, 2021-December, 626–631. <https://doi.org/10.1109/TENCON54134.2021.9707242>
- Kaya, M. (2023). Bayesian Optimization-based CNN Framework for Automated Detection of Brain Tumors. *Balkan Journal of Electrical and Computer Engineering*, 11(4), 395–404. <https://doi.org/10.17694/BAJECE.1346818>
- Kaya, M., & Çetin-Kaya, Y. (2024a). A novel ensemble learning framework based on a genetic algorithm for the classification of pneumonia. *Engineering Applications of Artificial Intelligence*, 133, 108494. <https://doi.org/10.1016/J.ENGAPPAI.2024.108494>
- Kaya, M., & Cetin-Kaya, Y. (2024b). A Novel Deep Learning Architecture Optimization for Multiclass Classification of Alzheimer’s Disease Level. *IEEE Access*, 12, 46562–46581.

- <https://doi.org/10.1109/ACCESS.2024.3382947>
- Khalefa, S. J. (2024). Finite element method and hybrid deep learning approaches: high-accuracy lung cancer detection model. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 7(3), 3017–3029. <https://doi.org/10.1007/S41939-024-00385-8/TABLES/2>
- Kim, M. G., Yoon, C., & Lim, H. G. (2024). Recent Advancements in High-Frequency Ultrasound Applications from Imaging to Microbeam Stimulation. *Sensors* 24(19), 6471. <https://doi.org/10.3390/S24196471>
- Kingma, D. P., & Ba, J. L. (2014). Adam: A Method for Stochastic Optimization. 3rd International Conference on Learning Representations, ICLR 2015 Conference Track Proceedings. <https://arxiv.org/abs/1412.6980v9>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Krstinić, D., Braović, M., Šerić, L., & Božić-Štulić, D. (2020). Multi-label Classifier Performance Evaluation with Confusion Matrix. 01–14. <https://doi.org/10.5121/CSIT.2020.100801>
- Geethu Lakshmi G, G., & Nagaraj, P. (2024). Squeeze-Inception V3 with Slime Mould algorithm-based CNN features for lung cancer detection. *Biomedical Signal Processing and Control*, 100, 106924. <https://doi.org/10.1016/J.BSPC.2024.106924>
- Gurkahraman, K., & Rukiye Karakış. (2021). Veri çoğaltma kullanılarak derin öğrenme ile beyin tümörlerinin sınıflandırılması. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(2), 997–1012. <https://doi.org/10.17341/gazimmfd.762056>
- Liao, F., Liang, M., Li, Z., Hu, X., & Song, S. (2019). Evaluate the Malignancy of Pulmonary Nodules Using the 3-D Deep Leaky Noisy-OR Network. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3484–3495. <https://doi.org/10.1109/TNNLS.2019.2892409>
- Memiş, S., Enginoğlu, S., & Erkan, U. (2019). A Data Classification Method in Machine Learning Based on Normalised Hamming Pseudo-Similarity of Fuzzy Parameterized Fuzzy Soft Matrices. *Bilge International Journal of Science and Technology Research*, 3(0), 1–8. <https://doi.org/10.30516/BILGESCI.643821>
- Mitra, S., Majumder, A. B., & Saha, T. (2023). An Observation and Analysis the role of Convolutional Neural Network towards Lung Cancer Prediction. *Baghdad Science Journal*, 20(6), 2568–2592. <https://doi.org/10.21123/BSJ.2023.9029>
- Mohamed, T. I. A., Oyelade, O. N., & Ezugwu, A. E. (2023). Automatic detection and classification of lung cancer CT scans based on deep learning and ebola optimization search algorithm. *PLOS ONE*, 18(8), e0285796. <https://doi.org/10.1371/JOURNAL.PONE.0285796>
- Munir, K., Elahi, H., Ayub, A., Frezza, F., & Rizzi, A. (2019). Cancer Diagnosis Using Deep Learning: A Bibliographic Review. *Cancers* 2019, Vol. 11, Page 1235, 11(9), 1235. <https://doi.org/10.3390/CANCERS11091235>
- Türkçetin, Ö. (2019). Akciğer Kanserinin Tespit Edilmesinde Derin Öğrenme Algoritmalarının Kullanılması. *Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü*.
- Rehman, A., Kashif, M., Abunadi, I., & Ayesha, N. (2021). Lung Cancer Detection and Classification from Chest CT Scans Using Machine Learning Techniques. 2021 1st International Conference on Artificial Intelligence and Data Analytics, CAIDA 2021, 101–104. <https://doi.org/10.1109/CAIDA51941.2021.9425269>
- Ren, Z., Zhang, Y., & Wang, S. (2022). Lcdae: Data augmented ensemble framework for lung

- cancer classification. *Technology in Cancer Research & Treatment*, 21, 15330338221124372. <https://doi.org/10.1177/15330338221124372>.
- Retico, A., Delogu, P., Fantacci, M. E., Gori, I., & Preite Martinez, A. (2008). Lung nodule detection in low-dose and thin-slice computed tomography. *Computers in Biology and Medicine*, 38(4), 525–534. <https://doi.org/10.1016/J.COMPBIOMED.2008.02.001>
- Ruder, S. (2017). An overview of gradient descent optimization algorithms *.
- Saini, M., & Susan, S. (2020). Deep transfer with minority data augmentation for imbalanced breast cancer dataset. *Applied Soft Computing*, 97, 106759. <https://doi.org/10.1016/j.asoc.2020.106759>.
- Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets. *PLOS ONE*, 10(3), e0118432. <https://doi.org/10.1371/JOURNAL.PONE.0118432>
- Sajjad, M., Khan, S., Muhammad, K., Wu, W., Ullah, A., & Baik, S. W. (2019). Multi-grade brain tumor classification using deep CNN with extensive data augmentation. *Journal of Computational Science*, 30, 174–182. <https://doi.org/10.1016/j.jocs.2018.12.003>
- Salomon, J., & Phelan, B. S. (2018). Lung Cancer Detection using Deep Learning Lung Cancer Detection using Deep Convolutional Networks Final Year Project. <https://doi.org/10.13140/RG.2.2.33602.27841>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1–48. <https://doi.org/10.1186/S40537-019-0197-0/FIGURES/33>
- Siegel, R. L., Miller, K. D., & Jemal, A. (2018). Cancer statistics, 2018. *CA: A Cancer Journal for Clinicians*, 68(1), 7–30. <https://doi.org/10.3322/CAAC.21442>
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings. <https://arxiv.org/abs/1409.1556v6>
- Song, Q. Z., Zhao, L., Luo, X. K., & Dou, X. C. (2017). Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. *Journal of Healthcare Engineering*, 2017. <https://doi.org/10.1155/2017/8314740>
- Sravani, M., Murthy, M. K., & Muppidi, S. (2024). Utilizing Visual Geometry Group (VGG16) and InceptionV3 convolutional Neural Network (CNN) models for accurate diagnosis of lung cancer: an Artificial Intelligence (AI)-based approach. *Multimedia Tools and Applications*, 83(19), 57477–57494. <https://doi.org/10.1007/S11042-023-17807-3/TABLES/1>
- Srivastava, N., Hinton, G., Krizhevsky, A., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929–1958.
- Su, Y., Li, D., & Chen, X. (2021). Lung Nodule Detection based on Faster R-CNN Framework. *Computer Methods and Programs in Biomedicine*, 200, 105866. <https://doi.org/10.1016/J.CMPB.2020.105866>
- Sultana, A., Khan, T. T., & Hossain, T. (2021). Comparison of Four Transfer Learning and Hybrid CNN Models on Three Types of Lung Cancer. 2021 5th International Conference on Electrical Information and Communication Technology, EICT 2021. <https://doi.org/10.1109/EICT54103.2021.9733614>
- Szegedy, C., Vanhoucke, V., Ioffe, S., & Shlens, J. (2015). Rethinking the Inception Architecture for Computer Vision.
- Talo, M., Baloglu, U. B., Yıldırım, Ö., & Rajendra Acharya, U. (2019). Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research*, 54, 176–188. <https://doi.org/10.1016/j.cogsys.2018.12.007>
- Tan, H., Bates, J. H. T., & Matthew Kinsey, C. (2022). Discriminating TB lung nodules from

- early lung cancers using deep learning. *BMC Medical Informatics and Decision Making*, 22(1), 1–7. <https://doi.org/10.1186/S12911-022-01904-8/FIGURES/5>
- Temurtaş, F. M., Yazdani, M., Yörük, Y. E., Aydemir, F., Yonar, D., Taştaltın, C., Gürol, İ., Temurtaş, F., Ebeoğlu, A., Salih, B., Köksal, D., Ahmet, K., & Emri, S. (2019). Akciğer kanseri tanısı için yeni bir yöntem. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 1(1), 35–48. <https://doi.org/10.46387/BJESR.629166>
- Terven, J., Cordova-Esparza, D. M., Ramirez-Pedraza, A., Chavez-Urbiola, E. A., & Romero-Gonzalez, J. A. (2024). Loss Functions and Metrics in Deep Learning. <https://arxiv.org/abs/2307.02694v4>
- Tian, Y., Zhang, Y., & Zhang, H. (2023). Recent Advances in Stochastic Gradient Descent in Deep Learning. In *Mathematics* (Vol. 11, Issue 3). MDPI. <https://doi.org/10.3390/math11030682>
- Tiraki, Y., Temurtaş, H., Serttaş, S., Bakır, Ç., Dumlupınar Üniversitesi, K., Eğitim Enstitüsü, L., Mühendisliği Bölümü, B., Türkiye, K., Fakültesi, M., & Mühendisliği Bölümü, Y. (2024). Çeşitli görüntülerin sınıflandırılması için yeni bir Evrişimsel Sinir Ağı önerisi A new Convolutional Neural Network proposal for classifying various images. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(1), 262–278. <https://doi.org/10.28948/ngumuh.1355726>
- TTOD. (n.d.). Türk Tıbbi Onkoloji Derneği - Toplum Bilgilendirme Sitesi. Türk Tıbbi Onkoloji Derneği. Retrieved March 16, 2024, from <https://www.kanser.org/saglik/toplum/kanser-turleri-alt-kategori/akciger-kanseri-nedir>
- Vdumoulin. (2023, March 23). GitHub - vdumoulin/conv_arithmetic: A technical report on convolution arithmetic in the context of deep learning. https://github.com/vdumoulin/conv_arithmetic
- WHO. (2023, June 26). Lung cancer. World Health Organization. <https://www.who.int/news-room/fact-sheets/detail/lung-cancer>
- WMC; WIKIMEDIA COMMONS; GorlapraveenGorlapraveen123. (2021, October 21). File:ResNet50.png - Wikimedia Commons. Own Work. <https://commons.wikimedia.org/wiki/File:ResNet50.png>
- Xie, Y., Xia, Y., Zhang, J., Song, Y., Feng, D., Fulham, M., & Cai, W. (2019). Knowledge-based Collaborative Deep Learning for Benign-Malignant Lung Nodule Classification on Chest CT. *IEEE Transactions on Medical Imaging*, 38(4), 991–1004. <https://doi.org/10.1109/TMI.2018.2876510>
- Xu, Z., Ren, H., Zhou, W., & Liu, Z. (2022). ISANET: Non-small cell lung cancer classification and detection based on CNN and attention mechanism. *Biomedical Signal Processing and Control*, 77, 103773. <https://doi.org/10.1016/J.BSPC.2022.103773>
- Yan, C., & Razmjooy, N. (2023). Optimal lung cancer detection based on CNN optimized and improved Snake optimization algorithm. *Biomedical Signal Processing and Control*, 86, 105319. <https://doi.org/10.1016/J.BSPC.2023.105319>
- Youlden, D. R., Cramb, S. M., & Baade, P. D. (2008). The International Epidemiology of Lung Cancer: geographical distribution and secular trends. *Journal of Thoracic Oncology : Official Publication of the International Association for the Study of Lung Cancer*, 3(8), 819–831. <https://doi.org/10.1097/JTO.0B013E31818020EB>
- Zhang, C., Aamir, M., Guan, Y., Al-Razgan, M., Awwad, E. M., Ullah, R., Bhatti, U. A., & Ghadi, Y. Y. (2024). Enhancing lung cancer diagnosis with data fusion and mobile edge computing using DenseNet and CNN. *Journal of Cloud Computing*, 13(1), 1–10. <https://doi.org/10.1186/S13677-024-00597-W/TABLES/2>

ÖZGEÇMİŞ

