

ESA Temelli Derin Öğrenme Modelleri ile Akciğer Kanseri Tespiti

Maryam Abbas Fadhıl Al Bayatı¹

¹Bilgisayar Mühendisliği / Fen Bilimleri Enstitüsü, Selçuk Üniversitesi, Konya, Türkiye

(meryem.beyatli94@gmail.com)

Özet –Akciğer kanseri, önemli bir küresel sağlık sorunu olmaya devam ederken dünya çapında kansere bağlı ölümlerin önde gelen nedenlerinden biri olmaktadır. Akciğer kanserinin erken teşhisi, hastaların yaşam beklentisini arttırmada ve yaşam kalitesini iyileştirmede çok önemli bir rol oynamaktadır. Bu çalışmada evrimsel sinir ağları temelli AlexNet, GoogleNet, VGG-16, VGG-19 ve ResNet adlı beş popüler derin öğrenme mimarisinin akciğer kanseri tespitindeki performansı değerlendirilmiştir. Sınıflandırma performanslarının değerlendirilmesi, özellikle akciğer kanseri tanısında yaygın olarak kullanılan Bilgisayarlı Tomografi (BT) görüntüleri üzerinde yapılmıştır. BT görüntüleri içeren veri seti Kaggle dataset platformundan elde edilmiştir. BT görüntülerinin derin öğrenme mimarileri için hazır hale getirilmesi için görüntü işleme adımları uygulanmıştır. Derin Öğrenme mimarileri kullanılarak akciğer kanserinin sınıflandırılması amaçlanarak oluşturulan bu çalışmada, AlexNet, GoogleNet, VGG16, ResNet, VGG19 modelleri ile sırası ile %91,72, %94,89, %95,17, %96,52, %95,10 sınıflama doğrulukları elde edilmiştir.

Anahtar Kelimeler: Akciğer kanseri, Derin Öğrenme, BT görüntüleri, VGG, AlexNet, GoogleNet, ResNet,

I. GİRİŞ

Kanser, dünyadaki tüm ülkelerde önde gelen ölüm nedenlerinden ve düşük yaşam kalitesi sebeplerinden biridir. Dünya Sağlık Örgütü'nün 2019 yılında yaptığı tahminlere göre kanser, 183 ülkenin 112'sinde 70 yaş üstü ölüm nedenleri arasında birinci veya ikinci sırada yer alırken, 23 ülkede ölüm nedeni olarak üçüncü veya dördüncü sırada yer almaktadır. Koroner kalp hastalığı ve felç nedeniyle ölüm oranlarındaki düşüş, kanserin önemini artmasına neden olmuştur. 2020' de 2,2 milyon yeni teşhis (tüm kanserler arasında yaklaşık %11,4) ve 1,8 milyon ölüm ile akciğer kanseri en çok teşhis edilen ikinci kanser ve ilk ölüm nedeni haline gelmiştir (Sung ve ark., 2021). Akciğer kanserinin teşhis ve tedavi sürecinde tıbbi görüntüleme teknikleri büyük önem taşımaktadır. Akciğer kanserinin tespitinde bilgisayarlı tomografi, göğüs röntgeni, manyetik rezonans görüntüleme, moleküler görüntüleme teknikleri ve pozitron emisyon tomografisi önemli rol oynamaktadır (Van den Abbeele ve Badawi, 2002). Kullanılan bu tekniklerin en büyük eksiklikleri arasında, patolojik durumları olan hastalar için

uygunsuzluk ve kanser tipini sınıflandıramama gibi sorunlar yer almaktadır. Bu sebeple kanserin erken teşhisi ve sınıflandırılması için yeni yaklaşımlara ihtiyaç vardır. Tıpta görüntüleme alanında değeri artan konulardan biri olarak derin öğrenme yöntemi giderek daha fazla kullanılmaya başlanmıştır. Yapay zekâ ve derin öğrenmeyi içeren tıbbi cihazların geliştirilmesi, doktorların akciğer kanseri için daha net ve hızlı kararlar vermeleri açısından son derece önemlidir. Günümüzde AlexNet, GoogleNet, VGG-16/19 ve ResNet gibi derin öğrenme mimarileri, tıbbi görüntülemede dahil olmak üzere çeşitli görüntü analizi görevlerinde olağanüstü performans göstermektedir. (Tekade ve Rajeswari, 2018) tarafından yürütülen akciğer nodülü tespiti ve kötü huyluluk seviyesinin erken tespiti amacıyla yapılan araştırmada LIDCIDRI, LUNA16 ve Data Science Bowl 2017 veri kümeleri kullanılarak CUDA özellikli GPU Tesla K20 üzerinde gerçekleştirilmiş olup, iki temel mimari üzerinden yürütülmüştür. U-Net mimarisi, akciğer CT tarama görüntülerinden akciğer nodüllerinin segmentasyonu için uyarlanmış ve 3D multipath VGG-16 benzeri

mimari, akciğer nodüllerinin sınıflandırılması ve kötü huyluluk seviyesinin tahmin edilmesi için kullanılmıştır. İki yaklaşımın birleştirilmesi sonucunda akciğer nodül tespiti için %95,66 doğruluk, %0,09 kayıp ve %90 dice katsayısı ve log kaybı için %38 doğruluk sonuçlarına ulaşılmıştır. (Türkçetin, 2019) yaptığı çalışmada Süleyman Demirel Üniversitesi Tıp Fakültesi Nükleer Tıp Anabilim Dalı'ndan elde ettiği veri setine ait iyi ve kötü huylu tümör bulunan 38 farklı hastadan 1968 tane elde edilen BT görüntüsünü kullanmıştır. Akciğer kanserinin teşhisi için görüntü işlemeye tabii tutulan BT görüntülerine histogram eşikleme uygulamış, görüntüdeki tümörlü bölgelerin görünürlüğünün bu işlem sonrası arttığını belirtmiştir. Görüntü işleme uygulanan BT görüntülerine Evrişimsel Sinir Ağı (ESA) derin öğrenme modeli uygulandığında % 93,48 sınıflama doğruluğu elde edilmiştir. Kullanılan bir diğer yöntem olan Deep Neural Network (DNN) derin öğrenme modelinin ise aynı veri setinde %91,65 doğruluk oranı sağladığı tespit edilmiştir. (Ayayna F. ve arkadaşları, 2023) akciğer kanserini sınıflandırmak için VGG16, VGG19 ve Xception mimarilerini kullanmış ve sırasıyla %94,19, %95,24 ve %90,14 sınıflama doğruluğu elde etmişlerdir.

Derin öğrenme mimarileri, büyük veri kümelerinden anlamlı özellikleri otomatik olarak öğrenmek ve çıkarmak için karmaşık sinir ağı mimarilerinden yararlanarak hastalık tespitinde gelişmiş doğruluk ve verimliliğe yol açmaktadırlar. (Krizhevsky ve ark. 2012), tarafından tanıtılan AlexNet ImageNet Large Scale Visual Recognition Challenge yarışmasında (ILSVRC) büyük bir farkla galip gelerek derin öğrenme alanında önemli bir etki yapmıştır. Aynı zamanda Rektifiye lineer birim (ReLU) aktivasyonları ve bırakma düzenlemesi (dropout regularization) ile birlikte daha küçük filtre boyutlarına sahip daha derin evrişimli sinir ağları kavramı tanıtılmıştır. Alexnet'in başarısı, derin öğrenme mimarilerinde daha fazla ilerlemenin yolunu açmıştır.

Inception-v1 olarak da bilinen GoogleNet (Szegedy ve ark. 2014) tarafından önerilmiş ve başlangıç modülleri fikrini ortaya atmıştır. Bu modüller, hesaplama karmaşıklığını azaltıp ağı karmaşık kalıpları öğrenmesini sağlarken birden fazla ölçek ve çözünürlükteki özellikleri verimli bir

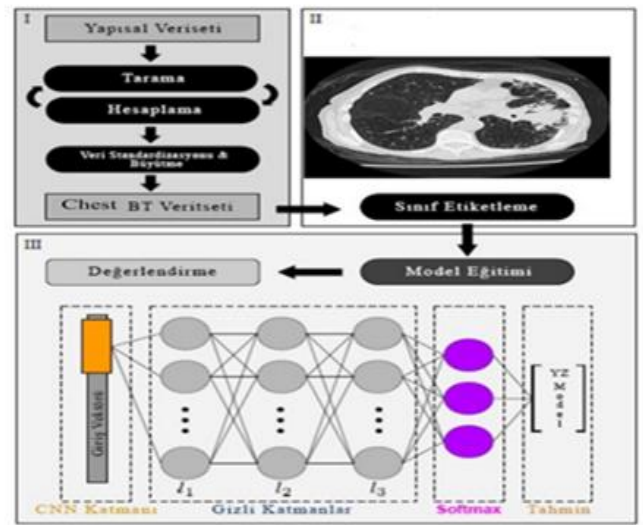
A. *Bilgisayarlı Tomografi (BT):*

şekilde yakalamaktadırlar. GoogleNet'in başlangıç modülleri, derin ağların verimliliğini önemli ölçüde artırmış ve ILSVRC 2014 yarışmasında en yüksek performansa erişmiştir. (Simonyan ve Zisserman 2014) tarafından geliştirilen VGG-16, sadeliği ve etkinliği ile ünlüdür. Bu mimari, müteakiben max-pooling katmanları olan, küçük 3x3 filtrelerle sahip 16 evrişimli katmandan oluşmaktadır. ve ILSVRC 2014 yarışmasında ikinciliği elde etmiştir. (He ve ark. 2015) tarafından önerilen ResNet derin sinir ağlarındaki bozulma sorununu çözmek için atlama bağlantılarını veya artık bağlantıları kullanmaktadır. Bu bağlantılar, ağı artık eşlemeleri öğrenmesini sağlayarak performans düşüşü olmadan daha derin katmanların eklenmesine olanak tanımaktadır. ResNet'in atlama bağlantıları, son derece derin sinir ağlarının eğitimini kolaylaştırmış ve ILSVRC 2015 yarışmasında önceki mimarileri geçerek birincilik elde etmiştir.

Bu çalışma, BT görüntülerinde akciğer kanseri tespitinde AlexNet, GoogleNet, VGG-16, VGG-19 ve ResNet' in performansını karşılaştırmaktadır. Bu çalışma ile elde edilen sonuçların, daha ileri araştırmalar ve potansiyel klinik uygulamalar için en uygun derin öğrenme mimarisinin seçilmesine yardımcı olması amaçlanmaktadır.

II. MATERYAL VE YÖNTEM

Bu çalışmada gerçekleştirilen işlemlere dair akış şeması Şekil 1 ' de görülmektedir.



Şekil 1. Çalışmaya ait akış diyagramı

CAT taraması olarak da bilinen BT, X-ışınlarıyla aynı temel teknolojiyi kullanır, ancak vücudun kesitsel görüntülerini oluşturmak için ek bilgisayar işlemleriyle birlikte kullanılır. BT taraması sırasında, X-ışını kaynağı ve dedektörleri hastanın etrafında dönerek çeşitli açılardan birden fazla görüntü yakalar ve doktorların vücudun iç yapılarını daha net görmelerine imkân verir. BT taramaları yumuşak dokuyu, kan damarlarını ve kemikleri görselleştirebilir ve genellikle kanser, kalp hastalığı ve akciğer hastalığı gibi durumları teşhis etmek ve izlemek için kullanılır.

Bu çalışmada kullanılan Bilgisayarlı Tomografi BT görüntüleri dört farklı veri setinden [Kaggle dataset(IQ-OTH/NCCD, CT Medical Images, Luna16 LungCancer, Chest CT-Scan images akciğer kanseri veri setleri)] genel kullanıma açık olan internet bilgi arşivinden elde edilmiştir.

B. Görüntü İşleme:

Görüntü işleme, dijital görüntüler üzerinde işlem yaparak, verimli ve anlamlı şekilde bilgi elde etmeyi amaçlar. Bu çalışmada görüntü işleme yöntemleri kullanılarak elde edilen akciğer BT görüntülerinin derin öğrenme mimarileri için hazır hale getirilmesi gerçekleştirilmiştir. Bunlardan renkli görüntülerin gri tonlamalı görüntülere dönüştürülmesi, görüntü işleme süreçlerinin hızını arttırmak ve hesaplama karmaşıklığını azaltmak için kullanılan bir işlemdir. Yeniden boyutlandırma, görüntünün kontrastını artırmak için kullanılmıştır. Aynı zamanda işlem süresinin azaltılması ve modelin daha hızlı eğitilmesinin sağlanması ile verilerin modellerin girdi beklentilerine uygun hale getirilmesi için kullanılan bir işlemdir. Yeniden boyutlandırılan görüntüler, daha sonra derin öğrenme modellerine girdi olarak verilerek, modelin eğitimi ve performansının değerlendirilmesi gerçekleştirilir (Haque ve Neubert, 2020).


C. Evrimsel Sinir Ağları (ESA):

ESA bilgisayarla görme de dahil olmak üzere, yapay zekanın birçok alanında kullanılan bir yöntemdir. Başlangıçta biyolojik görsel korteksten esinlenen ve Fukushima'nın Neocognitron'unun öncülüğünü yaptığı ESA'lar, (LeCun, Y. Ve Ark. 1998) LeNet-5 mimarisi ile popülerlik kazanmıştır.

Bu çalışmada kullanılan ESA temelli derin öğrenme modelleri aşağıdaki gibidir:

AlexNet mimarisi (2012)

Sinir ağlarına olan ilginin azaldığı bir dönemin ardından, Alex Krizhevsky tarafından tasarlanan AlexNet, 2012 ImageNet yarışmasında önceki tüm modellerden önemli ölçüde daha iyi performans göstererek ESA' lara yeniden dikkat çekmiştir. LeNet' e kıyasla daha derin ve daha geniş mimarilere sahiptir ve sinir ağlarını eğitmek için GPU kullanımını tanıtmıştır (Krizhevsky ve ark., 2012). Şekil 2 'de AlexNet mimarisi görülmektedir.




[Krizhevsky et al., 2012. ImageNet classification with deep convolutional neural networks]

Andrew Ng

Şekil 2. AlexNet Mimarisi


VGG16 mimarisi (2014)

Oxford'da Görsel Grafik Grubu tarafından geliştirilen VGGNet, ESA 'lardaki derinlik kavramını daha da ileriye taşımıştır. Sadeliği ve artan derinlikte üst üste yığılmış sadece 3x3 kıvrımlı katmanların kullanımıyla tanınan VGGNet modellerinin anlaşılması ve uygulanması kolaydır ve görüntülerden özellik çıkarma için kullanımı yaygındır (Simonyan ve Zisserman, 2014). Şekil 2' de VGG16 mimarisi görülmektedir.



Şekil 3. Vgg-16 Mimarisi
GoogLeNet/Inception mimarisi (2014)

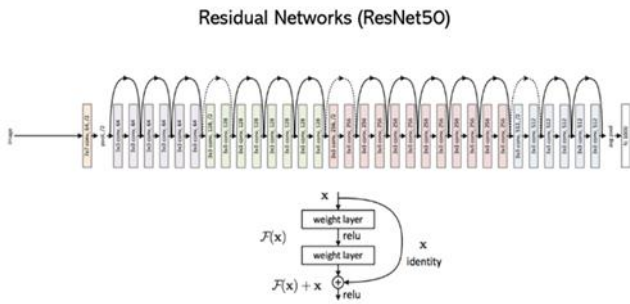
GoogLeNet, farklı görüş alanı boyutlarına sahip paralel evrişimli katmanlar kullanarak daha verimli hesaplama ve kapasite kontrolü sağlayan başlangıç modülü adlı yeni bir modül tanıtmıştır. Bu, ondan önceki tekdüze yapılandırılmış, sıralı modellerden bir ayrılmaya işaret etmektedir (Szegedy ve ark., 2015). Şekil 4’ de GoogleLeNet mimarisi görülmektedir.



Şekil 4. GoogleNet Mimarisi

ResNet mimarisi (2015)

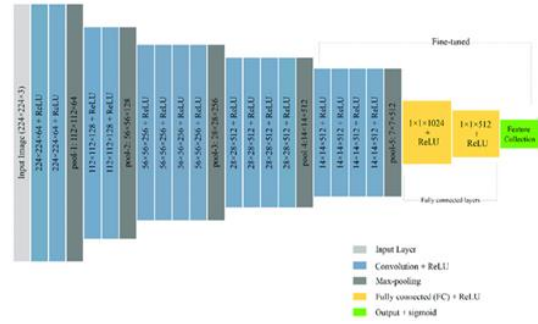
Microsoft Araştırma ekibi tarafından tanıtılan ResNet, 152 katmana kadar eğitime olanak tanıyan "bağlantıları atla" veya kısayollara sahip derin bir ESA mimarisidir. Bu mimari, derin ağları eğitmek için bir engel olan kaybolan gradyan problemini çözmektedir (He ve ark., 2015). Şekil5 ‘ de ResNet Mimarisi görülmektedir.



Şekil 5.ResNet Mimarisi

VGG19 mimarisi (2014)

VGG19, adını Oxford Üniversitesinde bulunan ‘Visual Geometry Group’ isimli gruptan almaktadır. Sonda bulunan 19 ise katman sayısını belirtmektedir. Ayrıca VGG’nin Vgg11, Vgg16 gibi farklı çeşitleri de bulunmaktadır (Hasan ve ark., 2022). Şekil6 ‘da VGG19 mimarisi görülmektedir.



Şekil 6.Vgg19 Mimarisi

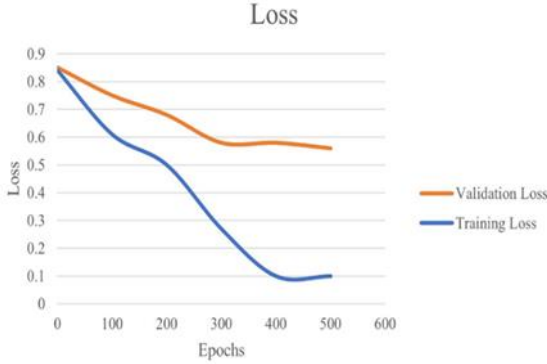
D. Hiperparametre Kalibrasyonu

Hiperparametre kalibrasyonu, makine öğrenimi modelinin performansını optimize etmek için kullanılan bir işlemdir. Makine öğrenimi algoritmaları, farklı hiperparametre değerleri kullanılarak eğitilir ve test edilir. Optimum hiperparametre değerleri, en yüksek doğruluğu veya en düşük hata oranını elde etmek için kullanılır. Hiperparametre kalibrasyonu, veri kümesi, model mimarisi ve optimizasyon algoritması gibi faktörlere bağlı olarak yapılabilir. Optimum hiperparametre ayarlaması, modelin aşırı uyum (overfitting) veya aşırı uyumsuzluk (underfitting) gibi problemlerden kaçınmasına yardımcı olabilir ve genellikle daha iyi sonuçlar elde edilmesini sağlar. Hiperparametreler, modelin performansını etkileyen parametrelerdir. Bunlar, öğrenme oranı, epoch sayısı, batch boyutu, regülarizasyon parametreleri ve ağıın derinliği gibi faktörlerdir. Örneğin, öğrenme oranı, modelin ne kadar hızlı öğreneceğini belirleyen bir hiperparametredir. Yüksek öğrenme oranı, modelin eğitim verilerinde aşırı uyumlama yapmasına neden olabilir. Düşük öğrenme oranı ise, modelin yavaş öğrenmesine ve minimuma ulaşmak için çok fazla epoch sayısı gerektirmesine neden olabilir. (Golovin ve ark., 2017).

E. Sınıflandırma Modellerinin Değerlendirmesi

Eğitim kaybı, eğitim sürecinde makine öğrenimi modelinin eğitim veri kümesindeki hatasını ifade eder. Akciğer kanseri teşhisi için derin öğrenme bağlamında, bu tipik olarak modelin tahminleri ile eğitim verilerindeki gerçek sonuçlar arasındaki farkı ölçen bir işlevi içerir. Makine öğreniminde "eğitim kaybı" ve "doğrulama kaybı", bir modelin eğitildiği verilerden ne kadar iyi öğrendiğini

izlemek için kullanılan kavramlardır. Eğitim kaybı, modelin eğitim veri kümesindeki hatasını ifade eder. Model eğitildikçe bu kaybı en aza indirmeye çalışır. Doğrulama kaybı ise modelin eğitim veri kümesinden ayrı bir doğrulama veri kümesindeki hatasını ifade eder. Bu parametre veri kümesi, modelin görünmeyen veriler üzerindeki performansını değerlendirmek ve aşırı uyumu tespit etmeye yardımcı olmak için kullanılır. (Chen, 2021). Şekil 7’ de Eğitim ve Doğrulama Kaybına bir örnek görülmektedir.



Şekil 7. Eğitim ve Doğrulama Kaybı örneği.

III. BULGULAR

Çalışmada Alexnet, Googlenet, VGG16, ResNet, VGG19 derin öğrenme modelleri kullanılmıştır. Veri setindeki BT görüntüleri kanserli ve sağlıklı olmak üzere ikili sınıflandırılmıştır. Veriler, test ve eğitim verileri alt klasörlerine ayrıştırılarak AlexNet, GoogleNet, VGG16, ResNet ve VGG19, modelleri ile eğitilmiş ve mimarilerin hiper parametreleri optimize edilmiştir. Eğitim aşamasında ilk parçanın eğitiminden sonra, modelin başarısı kontrol edilir ve modelin başarısına bağlı olarak geriye yayılım yardımıyla ağırlıklar yenilenir. Sonrasında başka bir eğitim kümesiyle model tekrar eğitilip ağırlıkları yeniden yenilenir. Modelin bu şekilde tüm eğitim adımlarında yenilenerek, en sağlıklı ağırlık değerlerini bulmaya çalışılmaktadır. Buradaki eğitim adımlarının tek tek her bir âdetine “Eğitim Tür Sayısı (Epoch)” denilir.

AlexNet mimarisi ile 2 sınıflı olan çalışmamızda Epoch değeri 1000, Learning rate değeri 0.0001, ValidationFrequency değeri 1 ve MiniBatch size değeri ise 32 olarak ayarlanmıştır. Modelde program en yüksek doğruluk değerine 37’ inci turda %91.72 ile ulaşmıştır. En düşük kayıp oranı ise 0.2515 olarak elde edilmiştir. Çizelge 1’ de AlexNet modeline ait sonuçlar görülmektedir.

Çizelge 1. Alexnet modeli için 2 sınıflı Eğitim tur (Epoch) tablosu

Tur	Doğruluk	Kayıp
1	0.6379	1.0159
24	0.8967	0.2832
25	0.8242	0.3665
30	0.8863	0.3047
37	0.9172	0.2515

GoogNet mimarisi ile 2 sınıflı çalışmamızda Epoch değeri 1000, Learning rate değeri 0.0001, ValidationFrequency değeri 1 ve MiniBatch size değeri ise 32 olarak ayarlanmıştır. Modelde program en yüksek doğruluk değerine 70’inci turda %94.89 ile ulaşmıştır. En düşük kayıp oranı ise 0.2222 olarak elde edilmiştir. Çizelge 2’ de GoogNet modeline ait sonuçlar görülmektedir.

Çizelge.2 GoogNet modeli için 2 sınıflı Eğitim tur (Epoch) tablosu.

Tur	Doğruluk	Kayıp
1	0.7651	0.5704
24	0.8251	0.3647
37	0.9291	0.2814
59	0.9303	0.2262
70	0.9489	0.2222

VGG16 mimarisi ile 2 sınıflı olan çalışmamızda Epoch değeri 1000, Learning rate değeri 0.0001, ValidationFrequency değeri 1 ve MiniBatch size değeri ise 32 olarak ayarlanmıştır. Modelde program en yüksek doğruluk değerine 28’inci turda %95.17 ile ulaşmıştır. En düşük kayıp oranı ise 0.1924 olarak elde edilmiştir. Çizelge 3’ de Vgg16 modeline ait sonuçlar görülmektedir.

Çizelge 3.VGG16 modeli için 2 sınıflı Eğitim tur (Epoch) tablosu.

Tur	Doğruluk	Kayıp
1	0.7559	0.8601
17	0.8525	0.3421
28	0.9240	0.1898
32	0.8920	0.3205
42	0.9517	0.1924

ResNet mimarisi ile 2 sınıflı olan çalışmamızda Epoch değeri 1000, Learning rate değeri 0.0001,

ValidationFrequency değeri 1 ve MiniBatch size değeri ise 32 olarak ayarlanmıştır. Modelde program 2 sınıflı en yüksek doğruluk değerine 70'inci turda %96.52 ile ulaşmıştır. En düşük kayıp oranı ise 0.1425 olarak elde edilmiştir. Çizelge 4' de ResNet modeline ait sonuçlar görülmektedir.

Çizelge.4. ResNet modeli için 2 sınıflı Eğitim tur (Epoch) tablosu.

Tur	Doğruluk	Kayıp
1	0.7550	0.6297
14	0.8554	0.3412
26	0.9400	0.1960
65	0.9468	0.1740
70	0.9652	0.1425

Vgg19 mimarisi ile 2 sınıflı olan çalışmamızda Epoch değeri 1000, Learning rate değeri 0.0001, ValidationFrequency değeri 1 ve MiniBatch size değeri ise 32 olarak ayarlanmıştır. Modelde program 2 sınıflı en yüksek doğruluk değerine 34'inci turda %95.10 ile ulaşmıştır. En düşük kayıp oranı ise 0.2120 olarak elde edilmiştir. Çizelge 1' de VGG19 modeline ait sonuçlar görülmektedir.

Çizelge.5 VG19 modeli için 2 sınıflı Eğitim tur (Epoch) tablosu.

Tur	Doğruluk	Kayıp
1	0.7500	1.3526
7	0.8322	0.4659
23	0.8999	0.2779
32	0.9359	0.2166
34	0.9510	0.2120

IV. SONUÇLAR

Derin Öğrenme modelleri kullanılarak akciğer kanserinin tespit edilip ikili sınıflandırılması amaçlanan bu çalışmada AlexNet, GoogleNet, VGG16, ResNet, VGG19 modelleri ile sırası ile %92,08, %95,17, %94.89,%96.52,%95.10 sınıflama doğrulukları elde edilmiştir. Sonuç olarak derin öğrenme yöntemleri akciğer kanseri tespitinde başarılı bir performans sergilemiştir ve elde edilen sayısal değerler, modellerin bu alandaki potansiyel uygulamaları için değerli bilgiler sunmaktadır. Bu çalışmada elde edilen sonuçların, akciğer kanseri tespiti için en uygun modeli seçimine ve derin öğrenme tekniklerinin bu alanda

daha da geliştirilmesine katkı sunacağı düşünülmektedir.

KAYNAKLAR

Ayayna, F.; Çalışkan, Abidin; Aslan, Ammar (2022). Akciğer Kanserinin Derin Öğrenme Yaklaşımları Kullanılarak Tespit Edilmesi, International Conference on Scientific and Academic Research (ICSAR'22), 1006-1012.

Chen, Y., Yi, H., Liao, C., Huang, P., & Chen, Q.,(2021), Visual measurement of milling surface roughness based on Xception model with convolutional neural network, Measurement, 186, 110217.

Golovin, D., Solnik, B., Moitra, S., Kochanski, G., Karro, J., & Sculley, D. (2017). Google vizier: A service for black-box optimization. In Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining (pp. 180-195).

Hamdalla, A., (2020), The IQ-OTHNCCD Lung Cancer Dataset, <https://www.kaggle.com/datasets/antonixx/the-iqothnccd-lung-cancer-dataset>.

Haque, I. R. I., & Neubert, J., (2020), Deep learning approaches to biomedical image segmentation, Informatics in Medicine Unlocked, 18, 100297.

Hasan, M. M., Islam, N., & Rahman, M. M., (2022), Gastrointestinal polyp detection through a fusion of contourlet transform and Neural features, Journal of King Saud University-Computer and Information Sciences, 34(3), 526-533

He, K., Zhang, X., Ren, S., Sun, J. (2015). Deep residual learning for imagerecognition. Proceedings of the IEEE conference on computer vision and pattern recognition, 77

Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems, 25, 1097–1105.

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324.

Mohamed, H., (2020),The Chest CT-Scan images Dataset, <https://www.kaggle.com/datasets/mohamedhanyyy/chest-ctscan-images>.

Szegedy,A.D.Erhan,A.Toshev,and D. Anguelov. (2014), Scalable object detection using deep neural networks.In CVPR,

Simonyan, K. ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F., (2021), Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries, CA: a cancer journal for clinicians, 91(3), 109-149.

Tekade, R., & Rajeswari, K. (2018). Lung cancer detection and classification using deep learning. In 2018 fourth international conference on computing communication control and automation (ICCUBEA) (pp. 1-5). IEEE.

Türkçetin, A. Ö., Bayrakçı, H. C., Danışman, I. I., & Aksoy, Ö. Ü. B., (2019), Akciğer kanserinin tespit

edilmesinde derin öğrenme algoritmalarının kullanılması. Isparta Isparta-2019.

Van Ginneken, B. (2019), The Luna16 Akciğer Kanseri Veri Kümesi:

<https://www.kaggle.com/datasets/fanbyprinciple/luna-lung-cancer-dataset>.

Van den Abbeele, A. D., & Badawi, R. D., (2002) Use of positron emission tomography in oncology and its potential role to assess response to imatinib mesylate therapy in gastrointestinal stromal tumors (GISTs), European journal of cancer, 18, 90-115.