



Derin Öğrenme Yöntemleri Kullanılarak BT Taramalarında Beyin Kanaması Teşhisinin Karşılaştırmalı Bir Analizi

Tuğrul Hakan Gençtürk^{1*}, Fidan Kaya Gülağız², İsmail Kaya³

^{1,2,3} Kocaeli Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

tuhage@gmail.com, fidan.kaya@kocaeli.edu.tr, hekimikaya@gmail.com

Öz

Teknolojinin gelişmesiyle birlikte yapay zekâ temelli uygulamalar pek çok alanda destek amaçlı kullanılmaktadır. Sağlık sektörü de bu tür uygulamaların yaygın kullanıldığı alanlardan bir tanesidir. Sağlık sektöründe teknolojik gelişime bağlı olarak meydana gelen bilgi artışı beraberinde radyolojik değerlendirmede uzmanlık gereğini doğurmuştur. Yoğun çalışma saatleri, sağlık kurumlarında her branştan uzmana ulaşamaması ve özellikle acil patolojilerde erken teşhisin önemi göz önünde bulundurulduğunda hekimlere teşhis sürecinde destek olacak uygulamalara olan ihtiyacın önemi anlaşılmaktadır. Çalışma kapsamında Bilgisayarlı Tomografi (BT) görüntüleri kullanılarak beyin kanamalarının tespitini gerçekleştirmek amacıyla güncel derin öğrenme yöntemlerinden Görsel Geometri Grubu (VGG), Artık Sinir Ağı (ResNet) ve EfficientNet mimarileri yine güncel bir veri kümesi olan PhysioNet'e uygulanmıştır. Modeller doğruluk, kesinlik, hassasiyet ve F1 skor metrikleri kullanılarak hem kendi aralarında hem de literatürdeki çalışmalarla karşılaştırılmıştır. Gerçekleştirilen çalışma ile veri kümesine uygun model seçiminin önemi güncel modeller üzerinden ortaya konulmuştur. EfficientNet-B2 modelinin başarısı hem literatürdeki çalışmalardan hem de makale kapsamında değerlendirilen modellerden yüksek olmuştur. Elde edilen sonuçlar güncel derin öğrenme modellerinin, beyin kanaması teşhisine yardımcı olabilecek potansiyelde olduğunu göstermiştir. Çalışma acil servislerin yükünü çeken pratisyen hekimleri en azından beyin kanamasının varlığı konusunda uyarıp kanama durumunun gözden kaçmamasını sağlaması ve erken teşhisi açısından önem arz etmektedir.

Anahtar kelimeler: Beyin kanaması, BT, Derin Öğrenme, EfficientNet, ResNet, VGG

A Comparative Analysis of Brain Hemorrhage Diagnosis on CT Scans Using Deep Learning Methods

Abstract

With the development of technology, artificial intelligence-based applications are used for support in many areas. The health sector is one of the areas where such applications are widely used. The increase in knowledge in the health sector due to technological development has led to the need for expertise in radiological evaluation. Considering the intensive working hours, the inaccessibility of specialists from every branch in health institutions and the importance of early diagnosis, especially in emergency pathologies, the importance of the need for applications that will support physicians in the diagnosis process is understood. In the scope of the study, Visual Geometry Group (VGG), Residual Neural Network (ResNet) and EfficientNet architectures, which are among the current deep learning methods, were applied to PhysioNet, a recent dataset, in order to detect brain hemorrhages using Computed Tomography (CT) images. The models were compared among themselves and with existing studies in the literature using accuracy, precision, recall and F1 score metrics. With this study, the importance of choosing the appropriate model for the dataset has been demonstrated through current models. The success of the EfficientNet-B2 model was higher than both the studies in the literature and the models evaluated within the scope of the article. The results show that current deep-learning models have the potential to help in the diagnosis of an intracranial hemorrhage. The study is essential in terms of early diagnosis of intracranial hemorrhage by at least alerting general practitioners, who bear the burden of emergency services, to the presence of intracranial hemorrhage and ensuring that the bleeding condition is not overlooked.

Keywords: Brain Hemorrhage, CT, Deep Learning, EfficientNet, ResNet, VGG

* Sorumlu yazar.
E-posta adresi: tuhage@gmail.com

Alındı : 5 Aralık 2022
Revizyon : 13 Şubat 2023
Kabul : 21 Şubat 2023

1. Giriş (Introduction)

Önleyici tıp sağlık halinin korunmasında en önemli ve en etkili yöntemdir (Zeng vd., 2021). Erken teşhis de bu amaçla kullanılan yöntemler arasında önde gelir (Zeng vd., 2021). Kalp ve sinir dokusu rejenerasyonu mümkün olmayan dokulardır. Bu nedenle nöronal hasarın önlenmesi bakımından erken teşhisin morbidite ve mortalite üzerindeki etkisi tartışılmazdır (Rogatsky vd., 1996).

Günümüzde yüksek enerjili kazaların artışı, sağlık ve teknoloji alanındaki gelişmelerle paralellik göstermektedir (TBI Data, 2022). Bu şekilde yüksek enerjili kazaların yaklaşık %80' ine kafa travmaları eşlik eder (Mirzai vd., 2005). Yine bunların yaklaşık %30' unda çeşitli ciddiyet ve boyutta beyin kanamaları eşlik eder (Mirzai vd., 2005). Beyin kanamalarında klinik takipte derin bilinç bozuklukları ardından yapılan teşhislerde tedavi ihtimali zayıftır (Rogatsky vd., 1996). Çünkü 3 dakika içinde beyin beslenmesi bozulduğunda geri dönüşsüz hasarlara neden olmaktadır (Rogatsky vd., 1996).

Travmaların teşhisinde kullanılan en hızlı ve yaygın yöntem BT'dir (Kuno vd., 2017). BT cihazları, günümüzde ikinci basamak ve üzeri hastanelerde bulunmaktadır (T. C. Sağlık Bakanlığı, 2019). Bu yaygınlık ve ek olarak BT görüntülerinin tüm vücut travmalarında kullanılabilir olması acil servislerde çalışan doktorlarımıza ciddi sorumluluklar yüklemektedir (Kuno vd., 2017). Acil servislerin pek çoğunda her bölümden uzmanlar olmadığı gibi acil uzmanları da bulunmamaktadır (Türkiye Ministry of Health Expert Board in Medicine, 2022). Pek çok acil servisin yükünü pratisyen doktorlarımız taşımaktadır (Türkiye Ministry of Health Expert Board in Medicine, 2022). Tüm travmaların BT görüntülerinin pratisyen doktorlar hatta acil uzmanları tarafından yorumlanması mümkün değildir (Türkiye Ministry of Health Expert Board in Medicine, 2022). Günümüzde bu eksiklik tele tıp yöntemleri ile uzaktan radyologlar tarafından giderilmeye çalışılmaktadır (Wallis ve McCoubrie, 2011). Ancak radyologlar çoğu zaman hasta kliniği hakkında bilgi sahibi değildir (Wallis ve McCoubrie, 2011). Bunlara ek olarak radyologların yüksek iş yükü de göz önünde bulundurulursa bu alanda sağlık personellerine destek olacak uygulamalara olan ihtiyaç ortaya çıkmaktadır (Wallis ve McCoubrie, 2011).

Teknolojinin gelişmesiyle birlikte sağlık sektöründe de yapay zekâ temelli uygulamaların kullanımı artış göstermiştir. Bu alanda kullanılabilecek teknikler makine öğrenmesi ve derin öğrenme temelli olmak üzere iki alt kategoride değerlendirilebilir. Makine öğrenmesi teknikleri model oluşturma sürecinde kullanılacak özellikleri yapılandırılmış olarak alırken, derin öğrenme teknikleri ses, görüntü gibi pek çok veriyi kullanarak özellik çıkarma sürecini otomatik olarak gerçekleştirir. BT görüntülerinin işlenmesi söz konusu olduğunda da derin öğrenme tekniklerinin daha yaygın tercih edildiği görülmektedir (Zhang vd., 2022;

Alquzi vd., 202; Morgan vd., 2022; Li vd., 2022; AlOthman vd., 2022).

Makale kapsamında BT görüntüler üzerinde erken teşhis sürecine destek olmak amacıyla derin öğrenme teknikleri kullanılarak beyin kanamalarının varlığının tespiti gerçekleştirilmiştir. Bu amaçla VGG, ResNet ve EfficientNet teknikleri kullanılmıştır. Hem bu teknikler arasında hem de tekniklerin kendi alt modelleri arasında kapsamlı bir karşılaştırma yapılmıştır. Yapılan karşılaştırma ile kullanılacak veri ile model seçimi arasındaki ilişki de ortaya konulmuştur.

Çalışmanın bundan sonraki bölümü şu şekilde organize edilmiştir. İkinci bölümde BT görüntüler üzerinde son yıllarda yapılan çalışmalara yer verilmiştir. Üçüncü bölümde kullanılan teknikler detaylı olarak açıklanmıştır. Elde edilen sonuçlara dördüncü bölümde yer verilmiştir. Sonuç bölümü ile çalışma tamamlanmıştır.

2. Literatür Araştırması (Literature Review)

Beyin kanamalarının BT görüntüler kullanılarak sınıflandırılması amacıyla son yıllarda yapılan çalışmalar incelendiğinde bu alanda yaygın olarak derin öğrenme tekniklerinin kullanıldığı tespit edilmiştir. Özellikle verinin kısıtlı olduğu durumlarda makine öğrenmesi tekniklerinden faydalanan çalışmalar da mevcuttur. Bu bölümde beyin kanamaları özelinde gerçekleştirilen sınıflandırma problemleri için hem makine öğrenmesi hem derin öğrenme tekniklerinden hangilerinin daha başarılı olduğu mevcut çalışmalar üzerinden özetlenmiştir.

Beyin kanamalarının türlerinin tespit edilmesi amacıyla Solorio-Ramírez vd. (2021) tarafından gerçekleştirilen çalışmada Açıklanabilir Yapay Zeka yaklaşımı kullanılmıştır. dMeans olarak adlandırılan bir öznitelik seçim algoritması ile beyin görüntülerinin sınıflandırılması gerçekleştirilmiştir. Önerilen yöntemin performansı Çok Katmanlı Algılayıcılar (MLP), Naive Bayes, K En Yakın Komşu (KNN), Destek Vektör Makinesi (SVM), Adaboost ve Rastgele Orman gibi geleneksel yöntemler ile karşılaştırılmıştır. Geliştirilen yöntem %86.50 doğruluk ve %91.60 özgüllük oranı ile karşılaştırılan yöntemlerden daha iyi bir sonuç elde etmiştir. Makine öğrenmesi tekniklerinin kullanıldığı başka bir çalışmada Alawad vd. (2020) tarafından gerçekleştirilmiştir. BT görüntülerinden beyin kanamasının tespiti ve sınıflandırılması için yeni bir yaklaşım önerilmiştir. Önerilen yöntem sınıflandırma için radyal tabanlı fonksiyon çekirdeğine sahip SVM tekniğini kullanmaktadır. Çalışmaya özgü olarak oluşturulan veri kümesi üzerinden yöntemin doğruluk değeri %99.5 olarak elde edilmiştir.

Beyin kanamalarının sınıflandırılması amacıyla derin öğrenme tekniklerini kullanan çalışmalar incelendiğinde yaygın olarak Evrimsel Sinir Ağı (CNN) temelli modellerin kullanıldığı görülmüştür. Mushtaq vd. (2021) tarafından BT görüntülerinden beyin kanaması sınıflandırmak için CNN modelleri

kullanılmıştır. Çalışmada iki farklı hibrit model (CNN + Uzun Kısa Süreli Bellek (LSTM) ve CNN + Geçitli Tekrarlayan Birim (GRU)) önerilmiştir. Modellerin doğruluğunun tespiti için beyin kanaması olan ve olmayan hastaların eşit olarak dengelendiği 200 BT görüntüsünden oluşan bir veri kümesi kullanılmıştır. Önerilen modellerden elde edilen en iyi sonuç %95 doğruluk oranına ve %90 özgüllük değerine sahiptir. CNN temelli olarak gerçekleştirilen başka bir çalışmada (Gautam ve Raman, 2021) beyinde kanama kaynaklı inme ve iskemik inme durumlarının sınıflandırılması gerçekleştirilmiştir. Görüntülerin kalitesini arttırmak için çok odaklı bir görüntü füzyonu tekniği kullanılarak ön işleme yapılmıştır. Sınıflandırma işlemi 13 katmanlı bir CNN mimarisi kullanılarak gerçekleştirilmiştir. Önerilen yöntemin doğruluğu Himalaya Tıp Bilimleri Enstitüsü tarafından sağlanan BT görüntülerden elde edilen iki farklı veri kümesi üzerinden gösterilmiştir. İlk veri kümesinde elde edilen en yüksek doğruluk değeri %98.77 iken ikinci veri kümesinden elde edilen en yüksek doğruluk değeri %93.33 olmuştur. RSNA 2019 veri kümesinde yer alan BT görüntüler kullanılarak Burduja vd. (2020) tarafından gerçekleştirilen çalışmada kafa içi kanama tespiti yapılmıştır. Yine LSTM ve CNN tekniklerini hibrit olarak kullanan bir model ile sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yöntem ile sınıflandırma işlemi için ortalama %96.00 doğruluk değeri elde edilmiştir. Beyin kanamalarının BT görüntüler kullanılarak sınıflandırılması problemi çözümü olarak otoenkoderlar ile AlexNet mimarisini birleştiren başka bir çalışmada (Toğaçar vd., 2019) %98.57 doğruluk değeri elde edilmiştir. Yalçın ve Vural (2022) tarafından beyin BT görüntüler üzerinden inmelerinin sınıflandırılması amacıyla gerçekleştirilen çalışmada U-net mimarisi kullanılmıştır. Önerilen U-net temelli yöntem ile inme sınıflandırılması için %98.9 doğruluk, iskemi ve kanama sınıflandırması için ise %98.5 doğruluk değeri elde edilmiştir. Konvolüsyonel sinir ağları ve BT görüntüler kullanılarak beyin kanaması tespiti ve sınıflandırılması amacıyla gerçekleştirilen başka bir çalışmada (Phan vd., 2019) %97.1 doğruluk değeri elde edilmiştir. Çalışmada görüntünün piksel değerlerine ek olarak Houndsfield değeri kullanılarak kanamanın oluşma zamanı ve olduğu bölge de tespit edilmiştir.

Beyin kanamalarının sınıflandırılması problemini özel bir kanama alt türünün sağlıklı beyin kanamalarından ayrılması şeklinde ikili sınıflandırma olarak gerçekleştiren çalışmalar da mevcuttur. Altuve ve Pérez (2022) sağlıklı beyin ve Intracerebral kanama (ICH) içeren beyin görüntülerinin ayrımı için ResNet-18 mimarisini kullanmışlardır. Önerilen yöntem ile sınıf dağılımları eşit 200 BT görüntüsü üzerinden %95.25 doğruluk ve %95.91 F1 skor değeri elde edilmiştir. ICH kanamalarının BT görüntülerinden tanımlanması ve sınıflandırılması üzerine yapılan bir çalışmada (Ko vd., 2020) CNN ve LSTM modelleri hibrit olarak kullanılmıştır. Önerilen modelin

sınıflandırma işlemi için doğruluk değeri %92 olarak elde edilmiştir. Lewick vd. (2020) intrakraniyal kanama tespiti amacıyla ResNet tabanlı bir konvolüsyonel sinir ağı mimarisi kullanmışlardır. Veri kümesi olarak Kuzey Amerika Radyoloji Derneği tarafından dört uluslararası üniversiteden toplanan 752.803 adet görüntü kullanılmıştır. Kanama türlerinin sınıflandırılması amacıyla oluşturulan ResNet-50 tabanlı bir konvolüsyonel ağ ile ortalama doğruluk değeri %93.3 olarak elde edilmiştir. ResNet-50 gibi önceden eğitilmiş ve ağırlıkları belirlenen modeller ile transfer öğrenmesi yapan bir diğer çalışma ise (Rahman vd., 2022) EfficientNet-B6 mimarisi ile %95.99 doğruluk oranına ulaşabilmiştir. Venugopal vd. (2021) çalışmalarında FFEDL-ICH ismini verdikleri bir yöntem geliştirmişlerdir. Geliştirilen yöntem dört aşamadan oluşmaktadır: ön işleme, resim segmentasyonu, özellik çıkarımı ve sınıflandırma. Özellik çıkarımı için ResNet-152 mimarisi kullanılmış ve derin sinir ağları ile sınıflandırma yapılmıştır. Bu şekilde doğruluk değeri %96.56 olarak bulunmuştur. AIMA-ICHDC (Meng vd., 2022) ismiyle geliştirilen bir başka yöntem ise sezgisel optimizasyon ve VGG-19 mimarisini bir arada kullanarak ikili sınıflandırmada %96.51 doğruluk değerine ulaşabilmiştir.

Çalışmamızda literatürde görüntü sınıflandırma için sıklıkla kullanılan ve başarılı oldukları ImageNet (Deng vd., 2009) veri kümesi üzerinden gösterilmiş (He vd., 2016; Tan ve Le, 2019; Simonyan ve Zisserman, 2015) VGG, ResNet ve EfficientNet mimarileri kullanılmıştır. Bu mimariler karmaşıklık olarak birbirlerinden ayrılmaktadır ve sınıflandırma problemlerinde sıklıkla sonuçları karşılaştırılmaktadır (Liu vd., 2020; Ravi vd., 2021; Wang vd., 2021; Rim vd., 2020). Literatürde beyin kanamalarının tespiti için bu mimarilerin karşılaştırıldığı bir çalışmaya rastlanmamıştır.

3. Metodoloji (Methodology)


Çalışmamızda beyin kanamalarının sınıflandırılması amacıyla günümüzde farklı sınıflandırma problemlerinde yaygın olarak kullanılan 3 farklı konvolüsyonel ağ mimarisi kullanılmıştır. Makalenin bu bölümünde kullanılan mimarilerinin detaylı açıklamaları verilmiştir.

3.1. VGG (Visual Geometry Group)

VGG (Simonyan ve Zisserman, 2015) büyük ölçekli veri kümelerinde görüntü tanıma yapabilmek amacıyla geliştirilmiş birden fazla katmana sahip standart bir CNN mimarisidir. Yenilikçi nesne tanıma modellerinin temelini oluşturmaktadır. Çalışmamızda VGG'nin özel mimarileri olan VGG-11, VGG-13 ve VGG-16 kullanılmıştır. VGG-11 mimarisi 8 evrişim katmanı ve 3 tam bağlantılı katmandan oluşur. Girdi olarak 224x224x3 boyutlarında RGB görüntüleri alır. Mimari içerisinde ilerledikçe derinleşmektedir ve parametre sayıları artmaktadır. Parametre sayıları

havuzlama katmanları sayesinde azaltılır. VGG-11 içerisinde havuzlama katmanları her aşamada kullanılmak yerine ağ içerisinde dağıtık halde

bulunmaktadır. Son aşamada ise sınıflandırmayı gerçekleştirmek için softmax sınıflandırıcısı kullanılır. VGG-11 mimarisi Şekil 1’de gösterilmiştir.



Şekil 1. VGG-11 Ağ mimarisi (VGG-11 Network architecture)

VGG-13 ve VGG-16 mimarileri VGG-11 mimarisi ile ortak girdi ve çıktı katmanlarına sahiptir. Mimariler evrişimli katmanların bulunduğu ve özellik çıkarımı

yapılan kısımda özelleşmektedir. Mimarilerin katmanları ve farklılaştıkları kısımlar Tablo 1’de gösterilmektedir.

Tablo 1. VGG Ağ mimarisi genel katman tablosu (VGG Network architecture general layer table)


Model	Özellik Çıkarımı				
	1. Blok	2. Blok	3. Blok	4. Blok	5. Blok
VGG-11	Conv3-64	Conv3-128	Conv3-256 Conv3-256	Conv3-512 Conv3-512	Conv3-512 Conv3-512
VGG-13	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
VGG-16	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
			Conv3-256	Conv3-512	Conv3-512

VGG mimarilerinde konvolüsyon katmanları özellik çıkarıcı olarak 5 blok halinde incelenebilir. Her blok içerisinde küçük boyutlu (3x3) filtreler kullanılmaktadır. VGG-11 ve VGG-13 tasarımlarını birbirinden ayıran sadece ilk iki bloktaki seviye sayısıdır. VGG-11 mimarisinden VGG-13 mimarisini oluşturmak için aynı konfigürasyona sahip ilk iki blok eklenir. Buna benzer şekilde, VGG-16 ve VGG-19 tasarımları üçüncü bloktan beşinci bloğa kadar kademeli olarak katmanlar eklenerek oluşturulur. Aynı zamanda özellik uzayını yoğunlaştırmak için her bloğun sonuna bir maksimum havuzlama katmanı eklenir. Maksimum havuzlama katmanında 2 adımlı bir (2x2) filtre kullanılır.

3.2. ResNet (Residual Neural Network)

ResNet (He vd., 2016) özel bir CNN mimarisidir ve yalnızca konvolüsyon katmanlarından oluşur. Temelde katman bloklarının kısayol bağlantıları kullanılarak atlanması fikrini gerçekleştirmektedir. Her iki katmanda bir artık bağlantılar kullanır. Bir artık

bağlantı, konvolüsyon ağının çıktısını takip eden konvolüsyonel katmanın çıkışına bağlar. Özellik haritalarının çözünürlüğü ve kanal sayısı ağ içerisinde ilerledikçe azalmaktadır. Buna ek olarak evrişim filtrelerinden sonra, bir ortalama havuzlama katmanına, tahmin yapmak için ise mimarinin çıkışında tam bağlantılı katmana sahiptir. Aynı zamanda modelin artık ağlar dışında devam eden çıktılarını ve artık evrişim katmanlarının girdilerini birleştirmek için basit bir toplam uygulanır. Bu şekilde özellik haritasının artıklarını kullanarak gerçekleştirilen bir eğitimin sadece özellik haritasının kullanıldığı bir eğitimden daha verimli olduğu görülmüştür (He vd., 2016). ResNet ağının 18 katman, 34 katman ve 101 katman gibi değişen parametrelerde katman sayısı içeren çeşitli mimarileri bulunmaktadır. ResNet-50’nin genel mimarisi Şekil 2’de gösterilmiştir. Tablo 2’de çalışmada kullanılan iki model olan ResNet-50 ve ResNet-101 mimarilerinin katmanları detaylı olarak gösterilmiştir.



Şekil 2. ResNet-50 Ağ mimarisi (ResNet-50 Network architecture)

Tablo 2. ResNet Ağ mimarisi genel katman tablosu (ResNet Network architecture general layer table)


Model	Özellik Çıkarımı				
	1. Blok	2. Blok	3. Blok	4. Blok	5. Blok
ResNet-50	7x7, 64, Stride 2	3x3, MaxPool, Stride 2	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
ResNet-101		3x3, MaxPool, Stride 2	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$

3.3. EfficientNet (EfficientNet)

EfficientNet (Tan ve Le, 2019) daha az parametreye sahip ve sınıflandırma doğruluğunu artıran CNN modelleri tasarlamak amacıyla geliştirilmiştir. Genişliği, derinliği ve çözünürlüğü eşit olarak ölçeklendirmek için bileşik ölçeklendirme tekniğini ve mobil ters darboğaz konvolüsyonunu (MBConv) kullanır. MBConv blokları kanalları genişleten ve ardından sıkıştırılan bir katmandan oluşur. Bu tasarım, geleneksel katmanlara kıyasla hesaplamayı neredeyse k^2 oranında azaltan derin ayrılabilir konvolüsyonlar içerir; burada k , 2D konvolüsyon penceresinin

genişliğini ve yüksekliğini temsil eden çekirdek boyutudur (Sandler vd., 2018). EfficientNet-B0'dan EfficientNet-B7'ye kadar yedi farklı mimariye sahiptir. EfficientNet-B0 modelinin şematik gösterimi Şekil 3'te verilmiştir.

Şekil incelendiğinde MBConv1, MBConv3 ve MBConv6 bloklarının tekrarlanarak kullanıldığı görülmektedir. Bunlar MBConv bloğunun farklı biçimleridir. Şekilde her bir blok içindeki kanal sayısının daha fazla sayıda filtre kullanılarak artırıldığı veya büyütüldüğü de görülmektedir. EfficientNet mimarisinin sekiz farklı modeline ait özellikler Tablo 3'te verilmiştir.



Şekil 3. EfficientNet-B0 Ağ mimarisi (EfficientNet-B0 Network architecture)

Tablo 3. EfficientNet modellerine ait genel özellik tablosu (General attribute table of EfficientNet models)


Model	Katman Sayısı	Giriş Çözünürlüğü	Özellik Vektör Boyutu
EfficientNet-B0	240	224x224	1280
EfficientNet-B1	342	240x240	1280
EfficientNet-B2	342	260x260	1408
EfficientNet-B3	387	300x300	1536
EfficientNet-B4	477	380x380	1792
EfficientNet-B5	579	456x456	2048
EfficientNet-B6	669	528x528	2304
EfficientNet-B7	816	600x600	2560

Tablo 3 incelendiğinde EfficientNet-B0'dan B7'ye kadar, giriş çözünürlükleri gibi katman sayısının da değiştiği görülmektedir. EfficientNet-B7 ise EfficientNet-B0'dan yaklaşık 3.50 kat daha derindir. Çalışmamızda EfficientNet modellerinden ilk dördü (B0-B4) kullanılarak BT görüntülerinden beyin kanamasının sınıflandırılması yapılmıştır. Modellerin karmaşıklığı arttıkça doğruluk değerlerinin düştüğü gözlemlendiği için B4 modelinden sonra gelen modeller çalışmada test edilmemiştir.

4. Deneysel Çalışma (Experimental Study)

4.1. Veri Kümesi (Data Set)

Makale kapsamında 82 BT taraması içeren PhysioNet (Hssayeni vd., 2020) veri kümesi kullanılmıştır. Veri kümesinde yer alan görüntüler iki radyolog tarafından kanama ve kırık türlerine göre etiketlenmiştir. Aynı zamanda her kesitteki ICH bölgeleri de radyologlar tarafından işaretlenmiştir.

Tablo 4. PhysioNet veri kümesinden alınan örnek görüntüler (Sample images from PhysioNet dataset)

Veri kümesinde yer alan taramalar toplamda 2812 kesit (2494 sağlıklı kesit, 318 beyin kanaması içeren kesit) içermektedir. Tablo 4'te hem kanama içeren hem de kanama içermeyen üçer adet tarama görüntüsü verilmiştir.

4.2. Hata Metrikleri (Error Metrics)

Çalışmamızda eğitilen modellerin değerlendirilmesi amacıyla doğruluk, kesinlik, hassasiyet ve F1 skor metrikleri kullanılmıştır. Doğruluk, sınıflandırıcı tarafından doğru yapılan tahminlerin tüm tahminlere oranını, kesinlik, doğru tahin ettiğimiz kanamalı görüntülerin, tüm kanamalı tahminlerimize oranını, hassasiyet, doğru tahin ettiğimiz kanamalı görüntülerin tüm kanamalı görüntülere oranını ve F1 skor, kesinlik ve hassasiyet metriklerinin harmonik ortalamasını ifade eder. Metriklere ait formüller sırasıyla Eşitlik (1), (2), (3) ve (4)'te verilmiştir. Eşitliklerde gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif değerler sırasıyla TP, TN, FP ve FN olarak gösterilmektedir. TP değeri kanamalı olarak tahmin edilen ve gerçekte de kanama içeren görüntülerin sayısını, TN değeri kanamasız olarak tahmin edilen ve gerçekte de kanama içermeyen görüntülerin sayısını, FP değeri kanamalı olarak tahmin edilen ancak gerçekte kanama içermeyen görüntülerin sayısını ve FN değeri ise kanamasız olarak tahmin edilen ancak gerçekte kanamalı olan görüntülerin sayısını temsil etmektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{F1 skor} = 2 * \frac{\text{Kesinlik} * \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (4)$$


4.3. Deneysel Sonuçlar (Experimental Results)

Model eğitimi öncesi veri kümesi %80 eğitim %20 test olacak şekilde bölümlenmiştir. Eğitim için VGG modellerinden VGG-11, VGG-13 ve VGG-16, ResNet modellerinden ResNet-50 ve ResNet-101 ve EfficientNet modellerinden de EfficientNet-B0, EfficientNet-B1, EfficientNet-B2 ve EfficientNet-B3 kullanılmıştır. Eğitim için 24GB RAM GTX1060 6GB

GPU ve i7-4770k işlemciye sahip bir sunucu kullanılmıştır. Modellere ait doğruluk değerleri Şekil


4'te gösterilmiştir.

Doğruluk



Şekil 4. Modellerden elde edilen doğruluk değerleri (Accuracy values obtained from models)

F1 Skor



Şekil 5. Modellerden elde edilen F1 skor değerleri (F1 score values obtained from models)

Grafik incelendiğinde en yüksek doğruluk oranının EfficientNet-B2 modeli ile elde edildiği görülmektedir. VGG, ResNet ve EfficientNet modelleri kendi içlerinde incelendiğinde (EfficientNet-B1-EfficientNet-B2 geçişi hariç) modellerin karmaşıklığındaki artışın doğruluk oranını düşürdüğü gözlemlenmiştir. Bu durum problemin karmaşıklığına uygun model seçiminin derin öğrenmedeki önemini göstermektedir. BT görüntüleri üzerinden gerçekleştirilen ikili sınıflandırma problemi (kanama var/yok) için karmaşıklığı düşük modeller daha yüksek doğruluk değeri vermiştir. Elde edilen

sonuçlar modelin probleme özgü olarak seçilmesi gerektiğinin açık bir göstergesidir. Sınıf etiketlerinde var olan dengesiz dağılım sebebiyle doğruluk değerine ek olarak F1 skor değeri de hesaplanmıştır. F1 skor değerine ait sonuçlar Şekil 5'te gösterilmiştir.

Şekilden de anlaşıldığı gibi VGG ve ResNet mimarileri için ağır karmaşıklığı yükseldiğinde model aşırı öğrenme eğilimine girmektedir. EfficientNet modellerinde de benzer durum söz konusudur ancak bu modellerde karmaşıklığın artışı ile F1 skor değerindeki düşüş oranı VGG ve ResNet modelleri kadar yüksek

değildir. Bu da bize EfficientNet modellerinin aşırı öğrenmeye karşı diğerlerinden daha dayanıklı

olduğunu göstermektedir.

Tablo 5. Modellerden elde edilen sınıflandırma sonuçları (Classification results obtained from models)

Yöntem	Doğruluk	Kesinlik	Hassasiyet	F1 Skor
VGG-11	95.9147	90.5085	88.8417	89.6511
VGG-13	89.1652	72.9331	62.5595	65.5927
VGG-16	94.3162	85.8968	85.8968	85.8968
ResNet-50	95.5595	89.5892	87.9603	88.7512
ResNet-101	90.9414	82.1807	65.6046	70.1121
EfficientNet-B0	97.1581	94.6005	90.9052	92.6458
EfficientNet-B1	96.6252	93.4523	89.2425	91.2035
EfficientNet-B2	97.3357	95.4043	91.0054	93.0554
EfficientNet-B3	96.0924	94.2456	85.5367	89.2639

Çalışma kapsamında değerlendirilen tüm metriklerin sonuçları detaylı olarak Tablo 5'te verilmiştir. Tablo 5 üzerinden genel bir değerlendirme yapılırsa, EfficientNet-B2 modelinin BT görüntüler kullanılarak beyin kanamalarının sınıflandırılması problemi için değerlendirilen modeller arasında en

uygun model olduğu söylenebilir. Tablo 6'te VGG-11, ResNet-50 ve EfficientNet-B2 modellerinin, PhysioNet veri kümesini kullanarak sınıflandırma yapan literatürdeki benzer çalışmalarla karşılaştırması verilmiştir.

Tablo 6. Kullanılan modeller ile PhysioNet veri kümesini kullanan çalışmaların karşılaştırması (Comparison of the used models and studies that using the PhysioNet data set)

Yöntem	Doğruluk	Kesinlik	Hassasiyet	F1 Skor
VGG-11	95.91	90.50	88.84	89.65
ResNet-50	95.55	89.58	87.96	88.75
EfficientNet-B2	97.33	95.40	91.00	93.05
Rahman vd. (2022)	95.99	94.24	85.53	89.26
Venugopal vd. (2021)	96.56	96.43	95.65	96.03
Meng vd. (2022)	96.51	96.50	95.25	95.87
Anupama vd. (2022)	95.73	95.79	94.01	94.89

Tablo 6'da yer alan sonuçlardan EfficientNet-B2 modelinin diğer modellerden daha başarılı olduğu görülmektedir. Elde edilen sonuçlar güncel derin öğrenme modellerinin, beyin kanaması tespiti için uzmanlara yardımcı olabilecek doğrulukta olduğunu göstermiştir.

5. Sonuçlar (Conclusions)

Travmatik beyin hasarı (TBH) vakalarında beyin kanamasının varlığını ve derecesini belirlemek için en çok kullanılan tıbbi görüntüleme yöntemi BT'dir. TBH sonrası kanama tanısı hızlı bir şekilde konulmalıdır çünkü birkaç dakikalık bir gecikme bile ölümle sonuçlanabilir. Ancak kanamanın manuel olarak tespit edilmesi zaman alır ve nitelikli radyologların her zaman hazır olması gerektirir (Grewal vd., 2018). Bu nedenle, radyologlarla eşit düzeyde çıkarım ve doğruluk sağlayabilen otomatik kanama tespit teknikleri binlerce hastanın hayatını kurtarma potansiyeline sahiptir.

Bu çalışmada açık bir veri kümesi üzerinden güncel sınıflandırma mimarileri kullanılarak beyin kanaması tespiti yapılmıştır. Güncel yöntemlerin probleme uygunluğu ve modellerin karmaşıklığına göre sonuçların nasıl değiştiği incelenmiştir. Problemin çözümü amacıyla VGG, ResNet ve EfficientNet

mimarileri kullanılarak transfer öğrenmesi yapılmıştır. Kullanılan modellerin değişik varyasyonları ile sonuçlar elde edilmiş ve sınıflandırma için en yüksek doğruluk değeri veren model belirlenmiştir. Elde edilen sonuçlara göre en yüksek doğruluk ve F1 skor sırasıyla %97.33 ve %93.05 ile EfficientNet-B2 mimarisinden elde edilmiştir.

Çalışma kapsamında yalnızca beyin kanamaları özelinde farklı sınıflandırma yöntemleri karşılaştırılmıştır. İlerleyen çalışmalarda beyin kanamalarının tespiti için daha özel bir model oluşturulması amacıyla çalışmalar yapılabilir. Aynı zamanda kanamanın varlığının tespitine ek olarak kanama olan bölgenin spesifik olarak belirlenmesi amacıyla segmentasyon modelleri geliştirilebilir. Özellikle başlangıç aşamasındaki kanamaların tespiti akut kanamalara göre kısmen zor olduğundan bu türlerde kanamalar içeren görüntülerle çalışan hem sınıflandırma hem segmentasyon modellerine erken teşhis aşamasında ihtiyaç vardır.

Kaynaklar (References)

- Alawad, D. M., Mishra, A., Hoque, M. T., 2020. AIBH: accurate identification of brain hemorrhage using genetic algorithm based feature selection and stacking. Machine Learning and Knowledge Extraction, 2(2), 56-77.
<https://doi.org/10.3390/make2020005>

- AlOthman, A. F., Sait, A. R. W., Alhussain, T. A., 2022. Detecting coronary artery disease from computed tomography images using a deep learning technique. *Diagnostics*, 12(9), 2073.
<https://doi.org/10.3390/diagnostics12092073>
- Alquzi, S., Alhichri, H., Bazi, Y., 2021. Detection of COVID-19 using EfficientNet-B3 CNN and chest computed tomography images. *ICICC 2021, International Conference on Innovative Computing and Communications*, February 2021, Delhi, India, pp. 365-373.
- Altuve, M., Pérez, A., 2022. Intracerebral hemorrhage detection on computed tomography images using a residual neural network. *Physica Medica*, 99, 113-119.
<https://doi.org/10.1016/j.ejmp.2022.05.015>
- Anupama, C. S. S., Sivaram, M., Lydia, E. L., Gupta, D., Shankar, K., 2022. Synergic deep learning model-based automated detection and classification of brain intracranial hemorrhage images in wearable networks. *Personal and Ubiquitous Computing*, 26, 1-10.
<https://doi.org/10.1007/s00779-020-01492-2>
- Burduja, M., Ionescu, R. T., Verga, N., 2020. Accurate and efficient intracranial hemorrhage detection and subtype classification in 3D CT scans with convolutional and long short-term memory neural networks. *Sensors*, 20(19), 5611.
<https://doi.org/10.3390/s20195611>
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., Fei-Fei, L., 2009. ImageNet: A large-scale hierarchical image database. *CVPR09, IEEE Conference on Computer Vision and Pattern Recognition*, 20-25 June 2009, Miami, Florida, USA, pp. 248-255.
- Gautam, A., Raman, B., 2021. Towards effective classification of brain hemorrhagic and ischemic stroke using CNN. *Biomedical Signal Processing and Control*, 63, 102178.
<https://doi.org/10.1016/j.bspc.2020.102178>
- Grewal, M., Srivastava, M. M., Kumar, P., Varadarajan, S., 2018. Radnet: Radiologist level accuracy using deep learning for hemorrhage detection in CT scans. *IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 4-7 April 2018, Washington, D.C, U.S., pp. 281-284.
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep residual learning for image recognition. *CVPR, IEEE Conference on Computer Vision and Pattern Recognition*, 27-30 June 2016, Las Vegas, Nevada, U. S., pp. 770-778.
- Hssayeni, M., Croock, M. S., Salman, A. D., Al-khafaji, H. F., Yahya, Z. A., Ghoraani, B., 2020. Intracranial hemorrhage segmentation using a deep convolutional model. *Data*, 5(1), 14.
<https://doi.org/10.13026/4nae-zg36>
- Ko, H., Chung, H., Lee, H., Lee, J., 2020. Feasible study on intracranial hemorrhage detection and classification using a cnn-lstm network. *EMBC, 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society*, 20-24 July 2020, Montreal, Canada, pp.1290-1293.
- Kuno, H., Sekiya, K., Chapman, M. N., Sakai, O., 2017. Miscellaneous and emerging applications of dual-energy computed tomography for the evaluation of intracranial pathology. *Neuroimaging Clinics*, 27(3), 411-427.
<https://doi.org/10.1016/j.nic.2017.03.005>
- Lewick, T., Kumar, M., Hong, R., Wu, W., 2020. Intracranial hemorrhage detection in CT scans using deep learning. *IEEE Sixth International Conference on Big Data Computing Service and Applications*, 3-6 August 2020, Oxford, United Kingdom, pp.169-172.
- Li, R., Xiao, C., Huang, Y., Hassan, H., Huang, B., 2022. Deep learning applications in computed tomography images for pulmonary nodule detection and diagnosis: A review. *Diagnostics*, 12(2), 298.
<https://doi.org/10.3390/diagnostics12020298>
- Liu, J., Wang, M., Bao, L., Li, X., 2020. EfficientNet based recognition of maize diseases by leaf image classification. *Journal of Physics: Conference Series*, 1693(1), 012148.
<https://doi.org/10.1088/1742-6596/1693/1/012148>
- Meng, F., Wang, J., Zhang, H., Li, W., 2022. Artificial intelligence-enabled medical analysis for intracranial cerebral hemorrhage detection and classification. *Journal of Healthcare Engineering*, 2022, 1-13.
<https://doi.org/10.1155/2022/2017223>
- Mirzai, H., Yağlı, N., Tekin, İ., 2005. Celal Bayar Üniversitesi Tıp Fakültesi acil birimine başvuran kafa travmalı olguların epidemiyolojik ve klinik özellikleri. *Ulusal Travma Dergisi*, 2, 146-152.
- Morgan, N., Van Gerven, A., Smolders, A., de Faria Vasconcelos, K., Willems, H., Jacobs, R., 2022. Convolutional neural network for automatic maxillary sinus segmentation on cone-beam computed tomographic images. *Scientific Reports*, 12(1), 1-9.
<https://doi.org/10.1038/s41598-022-11483-3>
- Mushtaq, M. F., Shahroz, M., Aseere, A. M., Shah, H., Majeed, R., Shehzad, D., Samad, A., 2021. BHCNet: neural network-based brain hemorrhage classification using head CT Scan. *IEEE Access*, 9, 113901-113916.
<https://doi.org/10.1109/ACCESS.2021.3102740>
- Phan A.-C., Nguyen T.-M.-N., Phan T.-C., 2019. Detection and classification of brain hemorrhage based on hounsfield values and convolution neural network technique. *RIVF, 2019 IEEE-RIVF International Conference on Computing and Communication Technologies*, 20-22 March 2019, Vietnam, pp.1-7.
- Rahman, A. I., Bhuiyan, S., Reza, Z. H., Zaheen, J., Khan, T. A. N., Karim, D. Z., 2022. Intracranial hemorrhage detection on CT scan images using transfer learning approach of convolutional neural network. *ICCA '22, 2nd International Conference on Computing Advancements*, 10-12 March 2022, Dhaka Bangladesh, pp. 171-177.
- Ravi, V., Narasimhan, H., Pham, T. D., 2021. EfficientNet-based convolutional neural networks for tuberculosis classification. In: Pham, T.D., Yan, H., Ashraf, M.W., Sjöberg, F. (eds) *Advances in Artificial Intelligence, Computation, and Data Science. Computational Biology*, 31, 227-244.
https://doi.org/10.1007/978-3-030-69951-2_9
- Rim, B., Kim, J., Hong, M., 2020. Gender classification from fingerprint-images using deep learning approach. *RACS '20, International conference on research in adaptive and*

- convergent systems, 13-16 October 2020, Gwangju Republic of Korea, pp. 7-12.
- Rogatsky, G., Mayevsky, A., Zarchin, N., Doron, A., 1996. Continuous multiparametric monitoring of brain activities following fluid-percussion injury in rats: preliminary results. *Journal of basic and clinical physiology and pharmacology*, 7(1), 23-44.
<https://doi.org/10.1515/jbcpp.1996.7.1.23>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.-C., 2018. Mobilenetv2: Inverted residuals and linear bottlenecks. *IEEE conference on computer vision and pattern recognition*, 18-23 June 2018, Salt Lake City, UT, USA, pp. 4510-4520.
- Simonyan, K., Zisserman, A. 2015. Very deep convolutional networks for large-scale image recognition. *ICLR 2015, 3rd International Conference on Learning Representations*, 7-9 May 2015, San Diego, CA, USA.
<https://doi.org/10.48550/arXiv.1409.1556>
- Solorio-Ramírez, J.-L., Saldana-Perez, M., Lytras, M. D., Moreno-Ibarra, M.-A., Yáñez-Márquez, C., 2021. Brain hemorrhage classification in CT scan images using minimalist machine learning. *Diagnostics*, 11(8), 1449.
<https://doi.org/10.3390/diagnostics11081449>
- T. C. Sağlık Bakanlığı, 2019. Sağlık İstatistikleri Yılıhğı. <https://dosyasb.saglik.gov.tr/Eklenti/40564,saglik-istatistikleri-yilligi-2019pdf.pdf?0>
- Tan, M., Le, Q., 2019. Efficientnet: Rethinking model scaling for convolutional neural networks. *ICML 2019, The 36th International conference on machine learning*, 10-15 June 2019, Long Beach, California, USA ,pp. 6105-6114.
- TBI Data | Concussion | Traumatic Brain Injury | CDC Injury Center. 2022, Mart 21.
<https://www.cdc.gov/traumaticbraininjury/data/index.html>
- Toğaçar, M., Cömert, Z., Ergen, B., Budak, Ü., 2019. Brain hemorrhage detection based on heat maps, autoencoder and CNN architecture. *UBMYK, 1st International Informatics and Software Engineering Conference*, 6-7 November 2019, Ankara, Turkey, pp. 1-5.
- Türkiye Ministry of Health Expert Board in Medicine. Türkiye emergency medicine specialty training curriculum. 2022, Mart 21.
<https://tuk.saglik.gov.tr/Eklenti/34065/0/acilipmufredatv24doc.doc>
- Venugopal, D., Jayasankar, T., Sikkandar, M. Y., Waly, M. I., Pustokhina, I. V., Pustokhin, D. A., Shankar, K., 2021. A novel deep neural network for intracranial haemorrhage detection and classification. *Computers, Materials & Continua*, 68(3), 2877-2893.
<https://doi.org/10.32604/cmc.2021.015480>
- Wallis, A., McCoubrie, P., 2011. The radiology report—are we getting the message across?. *Clinical radiology*, 66(11), 1015-1022.
<https://doi.org/10.1016/j.crad.2011.05.013>
- Wang, P., Liu, J., Xu, L., Huang, P., Luo, X., Hu, Y., Kang, Z., 2021. Classification of Amanita Species Based on Bilinear Networks with Attention Mechanism. *Agriculture*, 11(5), 393.
<https://doi.org/10.3390/agriculture11050393>
- Yalçın, S., Vural, H., 2022. Brain stroke classification and segmentation using encoder-decoder based deep convolutional neural networks. *Computers in Biology and Medicine*, 149, 105941.
<https://doi.org/10.1016/j.combiomed.2022.105941>
- Zeng, W., Li, G., Turbat, V., Hu, G., Ahn, H., Shen, J., 2021. Optimizing preventive medicine to bridge the gap between clinical medicine and public health for disease control in China: a lesson from COVID-19. *Preventive Medicine*, 143, 106324.
<https://doi.org/10.1016/j.ypmed.2020.106324>
- Zhang, M., Gu, S., Shi, Y., 2022. The use of deep learning methods in low-dose computed tomography image reconstruction: a systematic review. *Complex & Intelligent Systems*, 8, 5545–5561.
<https://doi.org/10.1007/s40747-022-00724-7>