



# Kahramanmaraş Sütçü İmam University

## Journal of Engineering Sciences



Geliş Tarihi : 12.07.2024  
Kabul Tarihi : 04.10.2024

Received Date : 12.07.2024  
Accepted Date : 04.10.2024

### KAFATASI KIRIKLARININ TEŞHİSİNDE YAPAY ZEKÂ: GÜNCEL DERİN ÖĞRENME MİMARİ PERFORMANSLARI

### ARTIFICIAL INTELLIGENCE IN SKULL FRACTURE DIAGNOSIS: CURRENT DEEP LEARNING ARCHITECTURE PERFORMANCES

Fidan KAYA GÜLAĞIZ<sup>1\*</sup> (ORCID: 0000-0003-3519-9278)

Tuğrul Hakan GENÇTÜRK<sup>1</sup> (ORCID: 0000-0002-2736-271X)

İsmail KAYA<sup>2</sup> (ORCID: 0000-0002-4128-5845)

<sup>1</sup> Kocaeli Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

<sup>2</sup> Niğde Ömer Halis Demir Üniversitesi, Tıp Fakültesi, Beyin Cerrahisi Bölümü, Niğde, Türkiye

\*Sorumlu Yazar / Corresponding Author: Fidan KAYA GÜLAĞIZ, fidan.kaya@kocaeli.edu.tr

#### ÖZET

Kafa travmaları, ciddi sonuçlara yol açabilen ve etkileri uzun yıllar sürebilecek sağlık sorunlarından biridir. Teşhis, ilk aşamada nörolojik muayene ile başlar ve gerektiğinde bilgisayarlı tomografi (BT) kullanılır. Kafatası kırıkları, diğer kafa travmalarına göre daha ciddi hasarlara eşlik ederler ve sıkça görülür. Özellikle ilk müdahalenin pratisyen hekimler ve acil uzmanları tarafından yapılması, BT görüntülerinin yorumlanmasında uzmanlık ve destek gerektirir. Bu noktada, özellikle ilk teşhis ve tanı aşamasında hekimlere destek olacak yapay zeka tekniklerinin varlığı büyük bir önem taşımaktadır. Bu çalışmada kafatası kırığının tespiti için kullanılabilecek dört farklı mimarinin alt modelleriyle birlikte kapsamlı bir karşılaştırması yapılmıştır. Bu amaçla Verimli Sinir Ağı (EfficientNet), Artık Ağlar (ResNet), Residual Networks with Aggregated Residual Transformations (ResNeXt) ve Maximum Vision Transformer (MaxVit) mimarileri çalışmaya dahil edilmiştir. Modellerin kafatası kırığını sınıflandırma açısından başarısı çalışmaya özgü olarak toplanan kapsamlı ve güncel bir veri kümesi üzerinden gösterilmiştir. Deneysel sonuçlar ile hem hangi yöntemin kafatası kırığı açısından daha uygun ve doğru sonuçlar verdiği ortaya konulmuş hem de güncel derin öğrenme mimarilerinin bu alandaki durumu özetlenmiştir.

**Anahtar Kelimeler:** BT, derin öğrenme, kafatası kırığı, sınıflandırma.

#### ABSTRACT

Cranial injuries are one of the health issues that can lead to serious consequences and have effects that may last for many years. Diagnosis begins with a neurological examination in the initial stage and employs computed tomography (CT) when necessary. Skull fractures are more frequently accompanied by severe injuries compared to other types of head trauma and are commonly observed. The initial intervention is often performed by general practitioners and emergency specialists, necessitating expertise and support in interpreting CT images. At this point, the presence of artificial intelligence techniques to assist physicians, particularly during the initial diagnosis and evaluation stages, is of significant importance. In this study, a comprehensive comparison of four different architectures that can be used for skull fracture detection has been made together with their sub-models. For this purpose, Efficient Neural Network (EfficientNet), Residual Network (ResNet), Residual Networks with Aggregated Residual Transformations (ResNeXt) and Maximum Vision Transformer (MaxVit) architectures are included in the study. The success of the models in terms of skull fracture classification is demonstrated on a comprehensive and up-to-date dataset collected specifically for the study. With the experimental results, both which method is more appropriate and accurate for skull fracture classification and the state of the art of current deep learning architectures in this field are summarized.

**Keywords:** CT, deep learning, skull fracture, classification.

## GİRİŞ

Günümüzde artan nüfus ve yaşantımızın kompleksleşmesi ile birlikte kafa travmaları önemli bir sağlık sorunu haline gelmiştir (Brain Trauma Foundation, 2024). Kafa travmaları, genel vücut travmalarının yaklaşık %11'ini oluşturur (Maconochie & Ross, 2007). Bu travmaların uzun vadeli etkileri, bireylerin yaşam kalitesini düşürmekte ve sağlık sistemine ciddi bir yük getirmektedir (Türkiye Cumhuriyeti Sağlık Bakanlığı, 2024). Kafa travmaları içinde kafatası kırıkları %74.6 oranında görülür (Sehlikoğlu vd., 2024). Kafa kemiklerinin kırıkları, korudukları nöral yapılar nedeniyle ciddi sonuçlar doğurabilecek travmalardır (Sehlikoğlu vd., 2024). Günümüz tıp pratiğinde, kafa kemiklerinin cerrahi müdahale gerektirmeyen kırıkları bile en azından hastane yatışı ve takibi gerektirir (Greenberg, 2010). Atlanmaları halinde kanamalar, beyin hasarları, epilepsi ve kistlere neden olabilirler (Greenberg, 2010). Bu nedenle, kırıkların tespit edilmesi büyük önem taşır.

Günümüzde kafatası kırıklarının görüntülenmesi için kullanılan bilgisayarlı tomografi (BT) cihazlarının sayısı artsa da, bu yöntemlerin yorumlanması uzmanlık gerektiren bir süreçtir (Türkiye Ministry of Health Expert Board in Medicine, 2024). Mevcut durumda, radyolog sayısının yetersizliği nedeniyle iş yükü yeterince karşılanamamaktadır (Türkiye Ministry of Health Expert Board in Medicine, 2024). Bu durum özellikle yoğun iş yükünde hızlı karar verme gerektiren teşhis ile tedavide gecikmelere, dolayısıyla mortalite ve morbidite oranlarının artmasına neden olmaktadır (Wallis & McCoubrie, 2011). Bu sebeple, otomatik raporlama sistemlerinin geliştirilmesi büyük önem taşımaktadır (Kaya vd., 2023).

İnternet kullanımının her geçen gün daha da yaygınlaşması ve teknolojideki hızlı gelişim beraberinde hem veri kaynaklarının, dolayısıyla veri türlerinin çeşitlenmesini hem de veri miktarlarının artmasını getirmiştir. Bu denli büyük miktarlara ulaşan verinin içerisinde elde edilebilecek faydalı bilgilerin varlığı insanların dikkatini çekmiştir. Bu nedenle bu alanda yıllardır hem kullanılabilir yeni modeller / mimariler hem de altyapı araştırmaları devam etmektedir. İstatistiksel teknikler kullanılarak verinin anlamlandırılması ile başlayan süreç el yapımı özelliklerin işlendiği makine öğrenmesi teknikleri ile devam etmiş ve günümüzde de özellik çıkarma sürecini otomatize eden derin öğrenme teknikleri ile gelişmesini sürdürmektedir. Özellikle derin öğrenme teknikleri sayesinde yalnızca yapılandırılmış formda bulunan veriler değil yapılandırılmamış ya da yarı yapılandırılmış formdaki veriler de işlenebilir ve anlamlandırılabilir hale gelmiştir. Bu alanda işlenebilir olarak karşımıza çıkan verilerden en dikkat çekenleri görüntü, video ve ses verileridir. Özellikle görüntü formundaki verilerin işlenebilir hale gelmesi tıp alanında pek çok farklı probleme özgü olarak geliştirilen modellerin de çıkış kaynağı olmuştur.

Tıp alanında teşhis aşamasında en yaygın kullanılan görüntüleme türleri BT ve MR'dır. MR, BT'ye göre çok daha detaylı görüntüleme sunsa da maliyet, manyetik özelliklerde implant bulduran hastalarda çekilememesi, kemik patolojilerde yetersiz olması ve uzun çekim süresince hareketsizlik gerektirmesi gibi sebeplerle travmalarda kullanımı uygun değildir (Greenberg, 2010). Bu nedenle ilk teşhis aşamasında BT görüntülerinin anlamlandırılması çok önemlidir. Derin öğrenme modelleri arasında görüntüleri girdi olarak alıp işleyebilen konvolüsyonel ağlar BT görüntülerini işleyebilmekte ve teşhis aşamasında pek çok farklı tıp alanında başarılı sonuçlar vermektedir.

Kafatası kırıklarının tespiti konusunda da BT, uzmanlar tarafından kullanılan en hızlı ve en etkili yöntemdir (Lin vd., 2022; Choi vd., 2022). Ancak kafatası kırıklarının çoğunluğunun piksel bazında değerlendirildiğinde küçük boyutlu olması ve kırık şekillerinin çeşitliliği, kafatası kırıklarının tespitini zorlaştırmaktadır (Lin vd., 2022). Bu nedenle uzmanlar bu alanda yapay zeka destekli teşhis ve tanı sistemlerine ihtiyaç duymaktadırlar. Literatürde bu alanda yapılan erken zamanlı çalışmalar (Zaki vd., 2008; Wan Zaki vd., 2009; Abubacker vd., 2013; Yamada vd., 2016; Yamada vd., 2018; Shao & Zhao, 2003) incelendiğinde yöntemlerin daha çok görüntü işleme teknikleri ile elde edilen ve el yapımı olarak adlandırılan özellikler ile tespit yapmaya çalıştıkları gözlemlenmiştir. Ancak bu modeller özellikle kafatasının karmaşık yapısı ve kırıkların irili ufaklı çok farklı yapılarda karşımıza çıkabilmesi gibi gerekçelerle yetersiz kalmaktadır (Lin vd., 2022). Derin ağlar bu sorunları ortadan kaldırarak özellik tespiti sürecini otomatize etmekte ve kırık bölgesini daha detaylı analiz edebilmemizi sağlayan çok daha fazla sayıda özelliği otomatik olarak çıkarmaktadır. Son yıllarda kafatası kırığı tespiti amacıyla BT görüntüleri üzerinden derin ağlar kullanılarak yapılan çalışmalar incelendiğinde kısıtlı sayıda çalışma olduğu tespit edilmiştir. Bu durumun en temel sebeplerinden bir tanesi bu alanda yeterli sayıda kullanıma açık etiketli veri kümesinin olmamasıdır.

Beyin hasarlarının tespiti konusunda bilinen en yaygın açık veri kümesi CQ500 ve Qure25k veri kümeleridir (Chilamkurthy vd., 2018). Bu veri kümeleri 5 farklı merkezden toplanmış sırasıyla 491 ve 21095 tarama içermektedir. Veri kümeleri içerisinde kırık içeren tarama sayısı Qure25k için 992 iken CQ500 için toplam 34 olarak listelenmiştir.

Aynı zamanda bu kırıklar sadece kafatası kırıkları türündedir. Veri kümelerinin elde edildiği bu çalışmada (Chilamkurthy vd., 2018) kafatası kırıklarının tespiti için DeepLab ve Random Forest teknikleri kullanılmıştır. Qure25k veri kümesinde 0.9244 eğrinin altında kalan alan (AUC) değeri elde edilirken, CQ500 veri kümesinde 0.9624 AUC değeri elde edilmiştir. Lin ve arkadaşları (Lin vd., 2022) tarafından kafatası kırıklarının el yapımı özellikler kullanılarak tespitinde karşılaşılan sorunların etkisini azaltmaya yönelik iki aşamalı bir bölgesel evrimsel sinir ağı (R-CNN) temelli yöntem tasarlanmıştır. Önerilen yöntem çalışmaya özgü olarak toplanan 110 hastaya ait BT görüntüleri üzerinden test edilmiştir ve Intersection over Union (IOU) değeri 0.5 alındığında ortalama kesinlik (AP) değeri 0.5388 olarak elde edilmiştir. Shan ve arkadaşları (Shan vd., 2021) tarafından gerçekleştirilen başka bir çalışmada YOLOv3 ve Modified attention U-net mimarileri kullanılarak kafa kırığı tespiti yapılmaya çalışılmıştır. Kafatası kırığı tanısı alan 4.782 hastanın BT taramaları kullanılarak gerçekleştirilen çalışmada YOLOv3 algoritması ile % 85.96 doğruluk, Modified attention U-net ile ise % 88.26 doğruluk değeri elde edilmiştir.

Kranial patolojilerin tespiti için gerçekleştirilen başka bir derin ağ temelli çalışmada (Guo vd., 2022) her bozukluk türünü sınıflandırmak için omurgası Artık Ağlar-18 (ResNet-18) olan ayrı bir konvolüsyonel sinir ağı ve sınırlandırıcı için ise iki katmanlı, tam bağlantılı bir ağ tasarlanmıştır. Tasarlanan bu mimari 4 farklı veri kümesi (retrospektif, prospektif, merkezler arası ve açık bir veri seti (CQ500)) üzerinde test edilmiştir. Veri kümeleri üzerinden kırık tespiti için elde edilen AUC değerleri sırasıyla 0.982, 0.978, 0.958, 0.971 olarak belirlenmiştir. Hem kafatası hem de yüz kemik kırıklarının tespiti için gerçekleştirilen farklı bir çalışmada (Wang vd., 2023) kırık tespiti için YOLOv4 ve kafatası ile yüz kemiklerinin segmentasyonu için ResUNet++ mimarisi kullanılmıştır. Eğitim ve test verileri iki farklı üçüncü seviye travma hastanesinden toplanmıştır. Kafatası kırıklarının tespitinde doğruluk değeri 0.8958 ve 0.8864 F1 skoru elde edilmiştir. Mangrulkar ve arkadaşlarının çalışmasında (Mangrulkar vd., 2021) giriş kafa görüntüsünden otomatik hasar tespiti için birleşik bir derin öğrenme modeli önerilmiştir. Çalışmada evrimsel sinir ağı (CNN) kullanılarak çıkarılan özellikler uzun kısa süreli bellek (LSTM) modeli ile sınıflandırılmıştır. Önerilen derin öğrenme modeli manuel olarak çıkarılan özellikler kullanılarak destek vektör makinesi (SVM), yapay sinir ağı (ANN) ve Naive Bayes sınıflandırıcıları ile sınıflandırılmıştır. Son olarak derin öğrenme modelinin sonuçları makine öğrenmesi modelleriyle karşılaştırılmıştır. Önerilen CNN-LSTM modeli 98.33 doğruluk oranıyla en yüksek başarıya sahip olmuştur. Çalışma kapsamında kullanılan veri kümesi ise 125 tanesi normal 355 tanesi hasarlı toplam 480 adet 3 boyutlu kafatası modelinden oluşmaktadır. Son olarak 2022 yılında akut travmatik beyin hasarlarının tespiti konusunda gerçekleştirilen bir derleme çalışmasında (Lin & Yuh, 2022) kafatası kırığı tespitinin diğer beyin hasarlarına nispeten daha zor olduğu bu nedenle bu alanda kısıtlı sayıda çalışma bulunduğu bahsedilmiştir. Bunlara ek olarak bu konuda gerçekleştirilen çalışmaların henüz ön çalışma aşamasında olduğu ve nispeten küçük veri kümeleri ile yapıldığı vurgulanmıştır.

Mevcut çalışmalar genel olarak değerlendirildiğinde hem yetersiz veri kümeleri hem de kafatası kırık tespiti probleminin diğer kafatası problemlerine göre zorlu olması sebebiyle sınırlı sayıda çalışma mevcuttur. Mevcut çalışmalar ise daha çok hibrit yöntemler üzerinden ilerlemektedir ancak son zamanlarda popüler olan CNN temelli model/mimarileri kapsamlı şekilde karşılaştıran ve modellerin bu alandaki güncel başarısını gösteren bir çalışmaya rastlanmamıştır. Bu nedenle çalışma kapsamında kafatası kırığının tespiti amacıyla kapsamlı bir veri kümesi oluşturulmuştur ve bu veri kümesi üzerinde Verimli Sinir Ağı (EfficientNet), ResNet, Residual Networks with Aggregated Residual Transformations (ResNeXt) ve Maximum Vision Transformer (MaxVit) mimarileri farklı alt modelleriyle kapsamlı şekilde karşılaştırılmıştır.


Çalışmanın geri kalanı şu şekilde organize edilmiştir. Çalışmanın gereç ve yöntemler bölümünde kullanılan mimari / modeller, veri kümesi ve değerlendirme metrikleri detaylı şekilde açıklanmıştır. Sonraki bölümde deneysel çalışmaya yer verilmiştir. Deneysel sonuçların yorumlandığı ve ileriye yönelik çalışmalardan bahsedildiği tartışma ve sonuçlar bölümüyle makale sonlandırılmıştır.

## GEREÇ VE YÖNTEMLER

Makalenin bu bölümünde ilk olarak kafatası kırıklarının tespiti amacıyla oluşturulan kapsamlı veri kümesi açıklanmıştır. İkinci alt bölümde sırasıyla EfficientNet, ResNet, ResNeXt ve MaxVit mimarileri ve bu mimarilerin alt modellerinin farkları verilmiştir. Üçüncü alt bölümde de yöntemlerin değerlendirilmesinde kullanılan metrikler formülleriyle detaylı olarak açıklanmıştır.

## Veri Kümesi

Niğde Ömer Halisdemir Üniversitesi'nden alınan 2023/77 Protokol numaralı girişimsel olmayan klinik araştırmalar etik kurul kararı ardından 1.12.2023 ile 31.5.2024 arasında rastgele travma nedenleriyle hastaneye başvuran 550 hastanın kranial BT görüntüleri anonim hale getirilerek toplandı. Hastaların demografik verilerinin kranial BT'de kemik değerlendirme açısından önemi olmadığından incelenmemiştir. Toplanan hasta verilerinden 1476 adet tarama görüntüsü kafatası kırığı içermektedir. Bu nedenle 1476 kafatası kırığı içeren görüntünün yanına 2079 adet kafatası kırığı içermeyen görüntü rastgele seçilerek eklenmiştir. Veri kümesinden örnek görüntüler Şekil 1'de gösterilmiştir. Sonuç olarak çalışmada kullanılan veri kümesi 3555 BT taraması içermektedir. Veri kümesinin etiketlenmesi için Computer Vision Annotation Tool (CVAT) kullanılmıştır. Etiketleme işlemi, görüntü etiketleme yöntemiyle gerçekleştirilmiştir. Bu süreçte, kafatası kırığı içeren her bir BT görüntüsüne bir beyin cerrahisi uzmanı tarafından "kırık" etiketi eklenmiştir. Kırık veriler içerisinde eğitim ve test verilerinin ayrılması sürecinde eğitim veri kümesindeki hasta taramalarının test kümesine karışmaması sağlanmıştır. Yani bölümlenme işlemi hasta bazlı olacak şekilde yüzde seksen eğitim yüzde yirmi test olarak gerçekleştirilmiştir.



Şekil 1. a. Sınıf 0 (Sağlam Kafatası)'a Ait Örnek Görüntüler b. Sınıf 1 (Kırık Kafatası)'e Ait Örnek Görüntüler

Tablo 1. Kafatası Kırığı İçeren Veri Kümeleri

Veri Kümesi	Kırıklı Görüntü Sayısı	Kullanılan Cihaz Özellikleri
CQ500 (Batch B1)	6	GE BrightSpeed, GE Discovery CT750 HD, GE LightSpeed, GE
CQ500 (Batch B2)	12	Optima CT660, Philips MX 16slice, Philips Access-32 CT
Qure25k	992	GE BrightSpeed, GE Brivo CT315, GE Brivo CT385, GE HiSpeed, GE LightSpeed, GE ProSpeed, GE Revolution ACTs, Philips Brilliance, Siemens Definition, Siemens Emotion, Siemens Sensation, Siemens SOMATOM, Siemens Spirit
Toplanan Veri kümesi	1476	Magnetom Aera; Siemens, Erlanger; Germany, Aquilion cx edition 128 slice ct-scanner; Toshiba, Japan

Tablo 1'de kafatası kırığı BT tarama görüntülerini içeren ve açık olarak erişilebilir olan veri kümeleri listelenmiş. Bunlardan CQ500 veri kümesi yeterli sayıda görüntü içermemesi sebebiyle çalışmaya dahil edilmemiştir. CQ500 veri kümesinin kapsamlı hali olan Qure25k veri kümesinde yeterli sayıda görüntü mevcuttur ancak bu veri



kümesi de görüntülerin çoğunun elde edildiği cihazların düşük sayıda sensörlü eski model cihazlar olması ile görüntü çözünürlükleri daha kötüdür. Bu nedenle patoloji tespit yetenekleri daha düşüktür.

## Yöntemler

Çalışmamız, geniş kapsamlı bir veri kümesi üzerinde modern CNN mimarilerinin performansını karşılaştırmayı amaçlamaktadır. Model seçiminde Torch kütüphanesinde mevcut en güncel yöntemler hesaplama kaynakları da göz önünde bulundurularak seçilmiştir. MaxViT özellikle CNN ve Transformer mimarilerini birleştiren hibrit yapısı nedeniyle tercih edilmiştir. Bu hibrit yapı sayesinde hem CNN'lerin yerel özellikleri yakalama kabiliyeti, hem de Transformer'ların küresel bağlamı anlama yeteneği bir arada değerlendirilmiştir.

Bu bölümde kafatası kırıklarının otomatik tespiti için karşılaştırılan EfficientNet, ResNet, ResNeXt ve MaxViT mimarilerinin yapısı ve bu çalışma kapsamında kullanılan modelleri detaylandırılacaktır. Son olarak, modellerin performansını değerlendirmek için kullanılan metrikler ve değerlendirme yöntemleri ele alınacaktır.

## EfficientNet


EfficientNet, (Tan & Le, 2019) 2019 yılında önerilen ve ağ mimarisinin ölçeklendirilmesi konusunda yeni bir yaklaşım getiren bir CNN mimarisidir. Bu mimari, ağın derinliği, genişliği ve giriş çözünürlüğü arasında optimum bir denge kurarak, daha az parametre ve hesaplama maliyeti ile yüksek doğruluk elde etmeyi amaçlar. EfficientNet'in temel prensibi, ağı tüm boyutlarını (derinlik, genişlik, çözünürlük) birlikte ve dengeli bir şekilde ölçeklendirmektir. Bu yaklaşım, "bileşik ölçeklendirme" olarak adlandırılır ve aşağıdaki Eşitlik (1), (2) ve (3) ile ifade edilir:

$$\text{Derinlik } (d) = \alpha^\varphi \quad (1)$$

$$\text{Genişlik } (w) = \beta^\varphi \quad (2)$$

$$\text{Çözünürlük } (r) = \gamma^\varphi \quad (3)$$

Burada  $\alpha$ ,  $\beta$ , ve  $\gamma$  sabit katsayılar,  $\varphi$  ise ölçeklendirme faktörüdür. Bu ölçeklendirme yöntemi, EfficientNet'in farklı boyutlarda (B0'dan B7'ye kadar) modeller oluşturmasına olanak tanır.



Şekil 2. Örnek Bir EfficientNet Bloğu.

EfficientNet'in yapı taşı, Mobil Inverted Bottleneck Convolutional (MBConv) bloklarıdır. Örnek bir blok Şekil 2'de gösterilmiştir. MBConv bloğu, yüksek performans ve verimlilik sağlayan beş ana adımdan oluşur. İlk olarak,  $1 \times 1$  konvolüsyon ile kanal genişletme işlemi yapılarak özellik uzayı genişletilir. Ardından, derinlemesine ayrılabilir konvolüsyon uygulanarak uzamsal özellikler yakalanır ve hesaplama verimliliği artırılır. Üçüncü adımda, Squeeze-and-Excitation (SE) modülü ile kanal bazında özellik yeniden kalibrasyonu gerçekleştirilir. Dördüncü adımda,  $1 \times 1$  konvolüsyon ile kanal daraltma işlemi yapılarak model boyutu küçültülür. Son olarak, giriş ve çıkış boyutları aynıysa bağlantı atlama uygulanarak gradyan akışı iyileştirilir. Bu yapı, geleneksel CNN bloklarından farklı olarak daha az parametre ile daha etkili özellik çıkarımı ve hesaplama verimliliği sağlar.

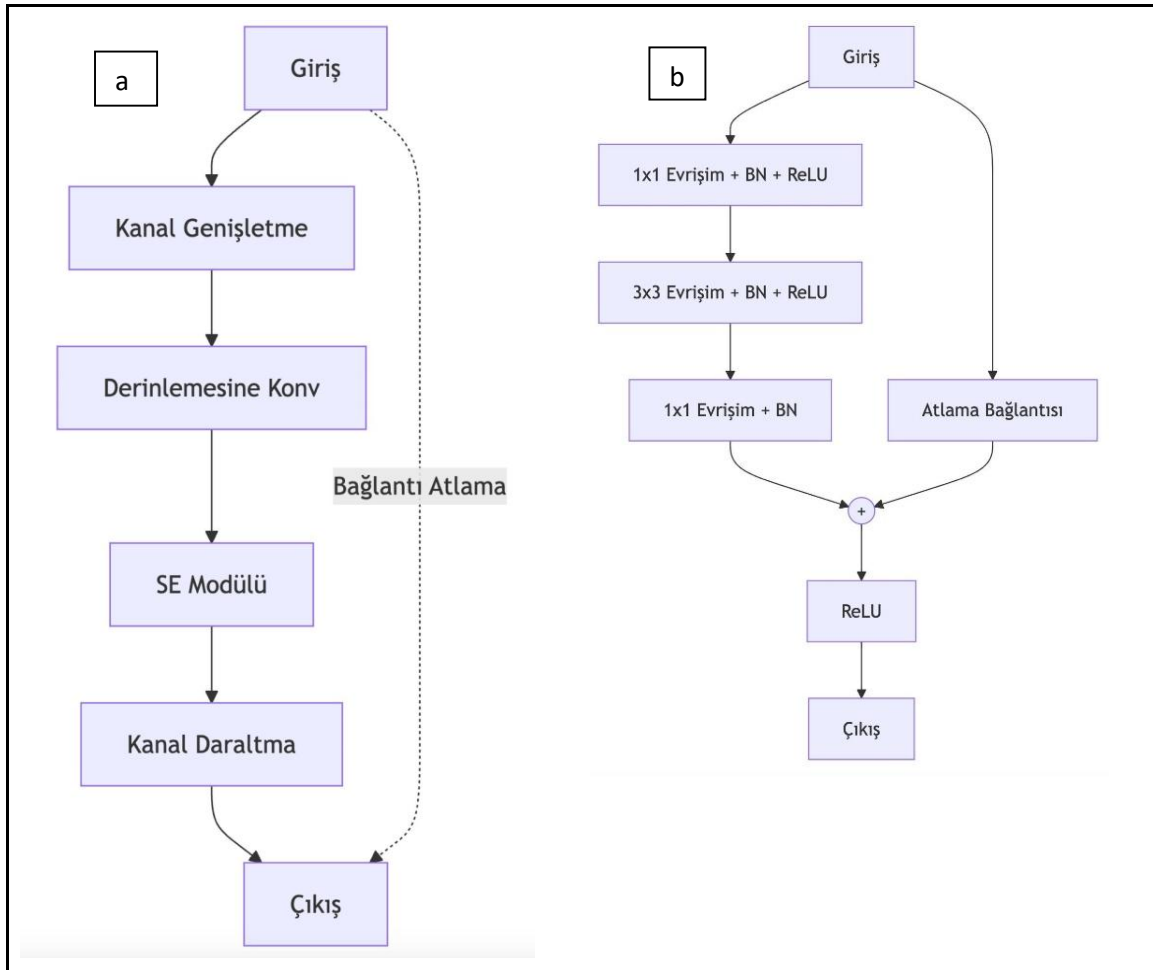
EfficientNet'in bu özellikleri, kafatası kırığı tespiti gibi karmaşık tıbbi görüntü analizi görevleri için onu ideal bir seçenek haline getirir. Modelin ölçeklenebilir yapısı, farklı boyut ve karmaşıklıkta kırıkları tespit etmede esneklik sağlar. Çalışmamızda, EfficientNet'in B0'dan B7'ye kadar olan tüm modelleri kullanılmış ve performansları karşılaştırılmıştır.

### ResNet

ResNet (He vd., 2016), 2015 yılında tanıtılan bir derin öğrenme mimarisidir. Derin ağlardaki gradyan kaybı problemini ele alarak, eğitim sürecini etkinleştirir. ResNet'in en önemli yeniliği, "atlama bağlantıları" veya "kısayol bağlantıları" olarak adlandırılan yapıdır. Bu yapı, ağın öğrenme şeklini değiştirerek her katmanın sadece "ek bilgi" veya "değişiklik" olduğunda öğrenmesini sağlar. Matematiksel olarak Eşitlik (4)'te gösterildiği gibi ifade edilir.

$$H(x) = F(x) + x \quad (4)$$

Burada  $H(x)$  katmanın çıktısını,  $F(x)$  öğrenilen değişikliği,  $x$  ise orijinal girişi temsil eder. Bu yaklaşım, derin ağlarda bilginin kolayca ilerlemesini sağlayarak gradyan kaybını azaltır. ResNet'in temel yapı taşı, artık bloğudur. Şekil 3. a bu bloğun yapısını göstermektedir:



Şekil 3. a. Temel ResNet Bloğu, b. ResNet Darboğaz (Bottleneck) Bloğu

Bu blok, iki evrişim katmanından oluşur ve her biri batch normalizasyonu ve ReLU aktivasyonu ile takip edilir. Atlama bağlantısı, giriş verisini doğrudan ikinci batch normalizasyonunun çıkışına ekler. ResNet, ResNet-18'den ResNet-152'ye kadar çeşitli derinliklerde modellere sahiptir. Daha derin ağlar için (ResNet-50 ve üzeri), ResNet artık bloklarında bir "darboğaz" tasarımı kullanır. Bu tasarım Şekil 3. b'de gösterilmiştir: Darboğaz tasarımı, boyutları azaltmak ve sonra artırmak için  $1 \times 1$  evrişimler kullanır ve bunların arasına  $3 \times 3$  evrişim yerleştirir. Bu yaklaşım, performansı korurken hesaplama karmaşıklığını azaltır. Çalışmamızda, kafatası kırığı tespitinde performanslarını karşılaştırmak için ResNet mimarisine ait ResNet-50, ResNet-101 ve ResNet-152 modelleri kullanılmıştır.

## ResNeXt

ResNeXt (Xie vd., 2017), ResNet mimarisinin geliştirilmiş bir versiyonudur. En önemli yeniliği, "kardinality" kavramını eklemesidir. Kardinality, bir bloktaki paralel yolların sayısını ifade eder. Geleneksel ResNet bloklarında tek bir yol varken, ResNeXt bloklarında birden fazla paralel yol bulunur. Bu yaklaşım, modelin öğrenme kapasitesini artırırken hesaplama karmaşıklığını kontrol altında tutar. ResNeXt'in temel yapı taşı olan blok, şu adımlardan oluşur:

1.  $1 \times 1$  konvolüsyon ile boyut azaltma
2.  $3 \times 3$  konvolüsyon ile özellik çıkarımı (kardinality sayısı kadar paralel yol)
3.  $1 \times 1$  konvolüsyon ile boyut artırma
4. Atlama bağlantısı ile giriş ekleme

Bu yapı, matematiksel olarak Eşitlik (5)'te verildiği gibi ifade edilebilir:


$$Y = X + \Sigma(T_i(X)) \quad (5)$$

Burada X giriş tensörünü,  $T_i$  i. paralel yolu, Y ise çıkış tensörünü temsil eder. ResNeXt'in bu yapısı, modelin daha zengin ve çeşitli özellikler öğrenmesine olanak tanır. Kardinality, ağırlık genişliğini ve derinliğini artırmaktan daha etkili bir şekilde model performansını artırabilir. Çalışmamızda, kafatası kırığı tespitinde ResNeXt mimarisinin ResNeXt-50 ve ResNeXt-101 modelleri kullanılmış ve performanslarını diğer mimarilerle karşılaştırılmıştır.

## MaxVit

MaxVit (Tu vd., 2022), görüntü sınıflandırma ve nesne tespiti gibi görevler için tasarlanmış yeni nesil bir derin öğrenme mimarisidir. Bu mimari, CNN ve Vision Transformers (ViT) modellerinin güçlü yönlerini birleştirerek daha etkili bir öğrenme sağlar. MaxVit'in temel yapı taşları şunlardır:

1. Mobil Ters Darboğaz Evrişim (MBCConv) Blokları: EfficientNet'te de kullanılan bu bloklar, yerel özellikleri verimli bir şekilde yakalar.
2. Blok Bazlı Öz-Dikkat: Görüntüyü bloklara bölerek her blok içinde öz-dikkat uygular. Bu, genel bağlamı yakalamaya yardımcı olur.
3. Izgara Bazlı Öz-Dikkat: Görüntüyü ızgara şeklinde bölerek, bloklar arası ilişkileri yakalar.
4. Çok Katmanlı Algılayıcı (ÇKA): Öğrenilen özellikleri işler ve son çıktıyı üretir.



Şekil 4. MaxVit Mimarisi Temel Bileşenleri

Şekil 4, MaxVit mimarisinin temel bileşenlerini ve veri akışını göstermektedir. Giriş verisi sırasıyla MBCConv bloklarından, blok-bazlı self-attention katmanından, ızgara-bazlı self-attention katmanından ve son olarak MLP katmanından geçer. MaxVit, bu yapı taşlarını kullanarak hem yerel hem de global özellikleri etkili bir şekilde öğrenir. Çalışmamızda, MaxVit mimarisinin MaxVit-Tiny, MaxVit-Small, MaxVit-Base ve MaxVit-Large modelleri kullanılmıştır.

## Değerlendirme Ölçütleri

Çalışmamız kapsamında karşılaştırılan modellerin performanslarını değerlendirmek amacıyla doğruluk, kesinlik, hassasiyet, F1 skor, AUC ve Gradyan ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) metrikleri kullanılmıştır. Metriklerin hesaplanması Eşitlik (6) - (11)'de gösterilmiştir (Han vd., 2012). Eşitliklerde yer alan TP değeri kafatası kırığı içerir olarak yapılan sınıflandırmalardan doğru olanların sayısını, TN değeri kafatası kırığı içermez olarak yapılan sınıflandırmalardan doğru olanların sayısını, FP değeri kafatası kırıklı olarak tahmin edilen ancak gerçekte kafatası kırığı içermeyen görüntülerin sayısını ve FN değeri ise kafatası kırığı içermez olarak tahmin edilen ancak gerçekte kafatası kırığı içeren görüntülerin sayısını temsil etmektedir. Son olarak P değeri TP+FN toplamını ve N değeri TN+FP değerini temsil etmektedir.

Yukarıda verilen kısaltmalar doğrultusunda doğruluk, model tarafından doğru yapılan sınıflandırmaların oranını ifade eder (Han vd., 2012) hesaplanması Eşitlik (1)'de (Han vd., 2012) gösterilmiştir, kesinlik, doğru tahmin ettiğimiz

kafatası kırığı içeren görüntülerin, tüm kırık tahminlerimize oranını, hassasiyet, doğru tahmin ettiğimiz kafatası kırığı içeren görüntülerin tüm kafatası kırığı içeren görüntülere oranını ve F1 skor, kesinlik ve hassasiyet metriklerinin harmonik ortalamasını ifade eder (Gençtürk vd., 2023; Gençtürk vd., 2024). Metriklere ait formüller sırasıyla Eşitlik (6), (7), (8) ve (9)'te verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{P + N} \quad (6)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (7)$$

$$\text{Hassasiyet} = \frac{TP}{P} \quad (8)$$

$$\text{F1 Skoru} = 2 * \frac{\text{Kesinlik} * \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (9)$$

AUC değeri ROC eğrisi üzerinden hesaplanır ve ikili sınıflandırma problemlerinde yaygın olarak kullanılmaktadır (Muschelli III, 2020). ROC eğrisi modelin False Positive Rate (FPR) olarak ifade edilen tahminleri ile True Positive Rate (TPR) olarak ifade edilen tahminleri arasındaki grafiksel ilişkiyi göstermektedir (Han vd., 2012). Çalışma kapsamındaki problemde FPR değeri kafatası kırığı içerir olarak yaptığımız sınıflandırmalardan yanlış olanların, toplam kafatası kırığı içermeyen görüntülere oranını ifade ederken, TPR değeri kafatası kırığı içerir olarak yaptığımız sınıflandırmalardan doğru olanların, toplam kafatası kırığı içeren görüntülere oranını ifade etmektedir. FPR değeri ROC grafiğindeki x eksenini, TPR ise y eksenine karşılık gelmektedir. TPR ve FPR değerlerinin hesaplanması Eşitlik 10 ve 11' de gösterilmiştir (Han vd., 2012). Bu değerler arasındaki ilişki bize ROC olarak ifade edilen olasılık eğrisini verir. Modelin olasılık eğrisinin altında kalan alanın yani AUC değerinin yüksek olması, TPR değerinin yüksek olmasına karşılık gelir ve bu istenen durumdur.

$$\text{TPR} = \frac{TP}{P} \quad (10)$$

$$\text{FPR} = \frac{FP}{N} \quad (11)$$

Bu metriklere ek olarak en başarılı modelin sınıflandırma sürecinde hangi noktalara odaklandığını gözlemleyebilmek için Grad-CAM (Selvaraju vd., 2017) görselleştirmesi kullanılmıştır. Grad-CAM, CNN tabanlı modellerde kullanılır ve modelin çalışma mantığının açıklanabilir olmasını sağlar (Bakchy vd., 2023).

## DENEYSEL ÇALIŞMA

Çalışmanın bu bölümünde EfficientNet, ResNet, ResNeXt ve MaxVit mimarileri ilk olarak alt modelleriyle kendi içlerinde karşılaştırılmıştır. Elde edilen sonuçlar sırasıyla Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te verilmiştir.

**Tablo 2.** EfficientNet Modelleri Sonuçları

	Doğruluk	Kesinlik	Hassasiyet	F1 Skoru
EfficientNet-B0	0,868458	0,868517	0,868458	0,866914
EfficientNet-B1	0,862801	0,862536	0,862801	0,86132
EfficientNet-B2	0,893918	0,89358	0,893918	0,893657
EfficientNet-B3	0,889675	0,889797	0,889675	0,888636
<b>EfficientNet-B4</b>	<b>0,898161</b>	<b>0,897826</b>	<b>0,898161</b>	<b>0,897873</b>
EfficientNet-B5	0,865629	0,867229	0,865629	0,863233
EfficientNet-B6	0,889675	0,894626	0,889675	0,887147
EfficientNet-B7	0,882603	0,882116	0,882603	0,882044

EfficientNet mimarisinde B0'dan B7'ye kadar 8 alt model için sonuçlar elde edilmiştir. Modeller kendi içerisinde karşılaştırıldığında kırık tespiti için B4 modeli, tüm metriklerde en yüksek değerlere sahip olup, en iyi performansı sergileyen modeldir. B1 ve B5 modelleri, diğer modellere göre daha düşük performans göstermektedir.



**Tablo 3.** ResNet Modelleri Sonuçları

	<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Hassasiyet</b>	<b>F1 Skoru</b>
ResNet-50	0,803395	0,825986	0,803395	0,789594
ResNet-101	0,820368	0,821699	0,820368	0,815931
<b>ResNet-151</b>	<b>0,861386</b>	<b>0,860753</b>	<b>0,861386</b>	<b>0,860889</b>

ResNet mimarisinde 50, 101 ve 151 alt modelleri için sonuçlar elde edilmiştir. ResNet-50 mimarisi için kesinlik metriği diğer metriklerle göre biraz daha yüksektir, ancak genel olarak en düşük performansa sahip modeldir. ResNet-151 modeli, tüm metriklerde en yüksek değerlere sahip olup, en iyi performansı sergileyen modeldir. ResNet-50 modeli, diğer modellere göre daha düşük performans göstermektedir ve daha az karmaşık görevler için uygun olabilir. ResNet-101 modeli, ResNet-50'ye kıyasla daha yüksek performans göstermektedir ve belirli senaryolar için başarılı sonuçlar verebileceği söylenebilir.

**Tablo 4.** ResNeXt Modelleri Sonuçları


	<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Hassasiyet</b>	<b>F1 Skoru</b>
<b>ResNeXt-50</b>	<b>0.891089</b>	<b>0.89913</b>	<b>0.891089</b>	<b>0.887992</b>
ResNeXt-101	0.845827	0.850372	0.845827	0.841443

ResNeXt mimarisinde 50 ve 101 alt modellerinin kafatası kırığı tespiti için performansları elde edilmiştir. Sonuçlara göre ResNeXt-50 modeli, tüm metriklerde en yüksek değerlere sahiptir aynı zamanda bu model, özellikle kesinlik ve hassasiyet metriklerinde de doğruluk ile paralel yüksek sonuçlar elde etmiştir. ResNeXt-101 modeli, ResNeXt-50'ye göre daha düşük bir performans göstermiştir ve ResNet-50 modelinde de olduğu gibi karmaşıklığı daha düşük kırık görüntüleri üzerinde daha başarılı olacağı söylenebilir.

**Tablo 5.** MaxVit Modelleri Sonuçları

	<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Hassasiyet</b>	<b>F1 Skoru</b>
<b>MaxVit- Tiny</b>	<b>0,8529</b>	<b>0,852714</b>	<b>0,8529</b>	<b>0,8528</b>
MaxVit- Small	0,850071	0,849694	0,850071	0,848239
MaxVit- Base	0,821782	0,820681	0,821782	0,819431
MaxVit- Large	0,851485	0,851587	0,851485	0,851535


MaxVit mimarisi için Tiny, Small, Base ve Large alt modelleri değerlendirilmiştir. Tiny modeli, tüm metriklerde en yüksek değerlere sahip olup, en iyi performansı sergileyen modeldir. Base modeli, diğer modellere göre daha düşük performans göstermektedir. Large ve Small modellerinin de Tiny modeline yakın sonuçlar verdiği görülmektedir.

**Şekil 5.** Farklı Güncel Derin Öğrenme Mimarileri İle Elde Edilen Sınıflandırma Sonuçları

Şekil 5'te karşılaştırma için seçilen dört mimarinin en başarılı olan alt modelleri karşılaştırılmıştır. Grafiğe göre EfficientNet-B4 modeli, hem doğruluk hem de F1 skoru açısından en yüksek değerlere sahip olup, genel olarak en iyi performansı sergileyen modeldir. MaxVit-Tiny modeli, hem doğruluk hem de F1 skoru açısından diğer modellere

göre daha düşük performans göstermiştir. ResNeXt-50 modeli ise EfficientNet-B4 modeline yakın bir doğruluk göstermiştir. Bu nedenle EfficientNet-B4 ve ResNeXt-50 modellerinin kafatası kırığı tespiti açısından daha uygun olduğu söylenebilir.


Şekil 6’da, dört farklı modelin (EfficientNet-B4, ResNet-151, ResNeXt-50 ve MaxVit-Tiny) karmaşıklık matrisleri gösterilmiştir. Her bir karmaşıklık matrisi, modelin sınıflandırma performansını gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) örnekler açısından daha iyi değerlendirmemizi sağlamaktadır. Matrisler incelendiğinde özellikle doğruluk açısından en başarılı olarak sınıflandırılan EfficientNet-B4 ve ResNeXt-50 modellerinin farkı daha net anlaşılmaktadır. Sınıflandırma probleminin amacı kafatası kırıklarının tespitidir. Dolayısıyla özellikle TP değerinin yüksek olması istenmektedir. TP değeri açısından değerlendirildiğinde EfficientNet-B4 modelinin ResNeXt-50 modeline göre üstünlüğü daha net anlaşılmaktadır. ResNeXt-50 modelinin doğruluk değerinin yüksek olması FP yani kırık içermeyen görüntüleri diğer modellere göre daha iyi tespit etmesinden kaynaklanmaktadır.



Şekil 6. a. EfficientNet-B4 Modeli Karmaşıklık Matrisi b. ResNet-151 Modeli Karmaşıklık Matrisi c. ResNeXt-50 Modeli Karmaşıklık Matrisi d. MaxVit-Tiny Modeli Karmaşıklık Matrisi

Doğruluk ve karmaşıklık matrisi üzerinden yapılan değerlendirmelere ek olarak en başarılı olarak tespit edilen EfficientNet-B4 modelinin sınıflandırma sürecinde hangi bölgelere odaklandığını gösteren Grad-CAM görselleri Şekil 7’de gösterilmiştir. Görseller modelin sınıflandırma aşamasında hem tek bir kırık bölgesi içeren hem de birden fazla kırığa sahip görüntülerde doğru bölgelere odaklandığını açık şekilde göstermektedir.

Tablo 6’da her mimarinin en başarılı modeli üzerinde uygulanan 10 katlı çapraz doğrulama işleminin sonucu da gösterilmiştir. Sonuçlar incelendiğinde ortalama doğruluğun yüzde yirmi test, yüzde seksen eğitim bölümlenmesi ile elde edilen doğruluk değerinden daha düşük olduğu ancak en başarılı modelin değişmediği ve EfficientNet-B4 olduğu tespit edilmiştir. Doğruluğun azalmasındaki sebep veri bölümlenmesinin on katlı çapraz doğrulamada yüzde doksan eğitim, yüzde on test olacak şekilde farklı oranlarda yapılmasıdır.



Şekil 7. EfficientNet-B4 Modelinin Grad-CAM Görselleştirmeleri

Tablo 6. Literatürde Yer Alan Çalışmalar Ve Çalışma Kapsamında Değerlendirilen Modellerin Sonuçları

	EfficientNet-B4	ResNet-152	ResNeXt-50	MaxVit- Tiny
1. Kat	0,7602	<b>0,8115</b>	0,6947	0,7766
2. Kat	<b>0,9016</b>	0,7828	0,7992	0,8197
3. Kat	0,7975	0,7934	<b>0,8058</b>	0,7851
4. Kat	<b>0,9211</b>	0,8465	0,8838	0,9087
5. Kat	<b>0,9231</b>	<b>0,9231</b>	<b>0,9231</b>	0,8932
6. Kat	<b>0,8725</b>	0,8017	0,8414	0,8612
7. Kat	<b>0,7488</b>	0,7093	0,7186	0,7279
8. Kat	0,7671	0,7032	<b>0,7831</b>	0,7055
9. Kat	<b>0,8767</b>	0,7854	0,8562	0,8196
10. Kat	0,8814	0,8770	0,8747	<b>0,8837</b>
Ortalama	<b>0,8450</b>	0,8034	0,8181	0,8181

Tablo 7’de çalışma kapsamında karşılaştırılan modeller ve literatürde kafatası kırığı tespiti yapan çalışmaların kapsamlı bir karşılaştırılması verilmiştir. Çalışmaların hepsinde doğruluk değeri bulunmaması ve aynı veri kümeleri üzerinden gerçekleştirilmiş olmamaları sebebiyle kesin bir karşılaştırma yapılması mümkün değildir. Ancak sonuçlar genel olarak değerlendirildiğinde kırıkların çok farklı çeşitliliğe sahip olması sebebiyle bu alanda derin öğrenme tabanlı yaklaşımlara ihtiyaç olduğu açık olarak görülmektedir

## TARTIŞMA VE SONUÇLAR

Hayati öneme sahip kafatası kırıklarının tespiti için, modern yaşamın oluşturduğu iş yükü altında sağlık çalışanlarına destek sağlamak amacıyla otomatize raporlama sistemlerinin geliştirilmesi, en önemli yapay zekâ problemlerinden biridir. Çalışma kapsamında bu probleme çözüm sunmak amacıyla güncel olarak toplanan kafatası kırığı ve farklı beyin hasarlarını içeren geniş bir veri kümesi üzerinde güncel derin öğrenme yöntemlerinin kafatası kırığı tespiti

açısından başarısı değerlendirilmiştir. Problemin çözümü için EfficientNet, ResNet, ResNeXt ve MaxVit mimarileri alt modelleriyle birlikte değerlendirilmiştir. Alt modellerin de işleme alınması problem çözümünde karmaşık modellere ihtiyaç var mıdır sorusunun da cevabını vermiştir. Elde edilen sonuçlara göre Efficient mimarisi, B4 modeliyle %89.81, ResNet mimarisi 151 alt modeliyle %86.13, ResNeXt mimarisi, 50 alt modeliyle %89.10 ve MaxVit mimarisi Tiny alt modeliyle %85.29 doğruluk değeri elde edilmiştir.

**Tablo 7.** Literatürde Yer Alan Çalışmalar Ve Çalışma Kapsamında Değerlendirilen Modellerin Sonuçları

Model	Veri Kümesi	Doğruluk	F1 Skoru	AUC	AP
DeepLab ve Random Forest (Chilamkurthy vd., 2018)	Qure25k	-	-	0,9244	
DeepLab ve Random Forest (Chilamkurthy vd., 2018)	CQ500	-	-	0,9624	
Önerilen İki Aşamalı R-CNN (Lin vd., 2022)	Çalışmaya özgü veri kümeleri	-	-	-	0,5388
YOLOv3 Modified attention U-net (Shan vd., 2021)	Çalışmaya özgü veri kümesi	85,96 88,26			
ResNet 18 + iki katmanlı FCN Guo vd., 2022	Çalışmaya özgü 3 farklı veri kümesi			0,982 0,978 0,958	
ResNet 18 + iki katmanlı FCN Guo vd., 2022	CQ500			0,971	
YOLOv4 (Wang vd., 2023)	Çalışmaya özgü veri kümesi	0,8958	0,8864		
CNN + LSTM (Mangrulkar vd., 2021)	Çalışmaya özgü veri kümesi	98,33	98,76		
EfficientNet-B4 ResNet-152 ResNeXt-50 MaxVit- Tiny	Çalışmaya özgü veri kümesi	0,898161 0,861386 0,891089 0,852900	0,897873 0,860889 0,887992 0,852800		

EfficientNet-B4 modeli en yüksek başarıya sahiptir ancak ResNeXt-50 modelinin de doğruluk açısından EfficientNet-B4 modeline yakın olduğu görülmüştür. Karmaşıklık matrisi üzerinden yapılan değerlendirme de EfficientNet-B4 modelinin TP yani kırıkları daha doğru tespit ettiği ResNeXt-50 modelininse FP durumları yani kırık içermeyen taramaları daha doğru tespit ettiği bu nedenle yakın sonuç elde edildiği tespit edilmiştir. Aynı zamanda kırık tespiti açısından çok yüksek karmaşıklığa sahip modellerin daha düşük başarı gösterdiği de elde edilen sonuçlar arasındadır.

Çalışma kapsamında yalnızca kafatası kırığının varlığının tespitine odaklanılmıştır. İlerleyen çalışmalarda mevcut veri kümesi üzerinde bölütlemeye uygun işaretlemelerin beyin cerrahisi uzmanları tarafından yapılması ve bölütleme açısından derin öğrenme mimarilerinin başarısının ortaya konulması hedeflenmektedir. Özellikle veri kümesi eksikliği ve kırık türlerinin çeşitliliği, aynı örüntüye sahip olmaması sebepleriyle sınırlı sayıda çalışma içeren bu alanda mevcut derin öğrenme yöntemlerinin doğruluğunu arttıracak teknikler veya yeni modeller geliştirilmesi de büyük bir ihtiyaç olarak tespit edilmiştir.

## KAYNAKLAR

Abubacker, N. F., Azman, A., Azrifah, M., & Doraisamy, S. (2013, December). An approach for an automatic fracture detection of skull dicom images based on neighboring pixels. In 2013 13th International Conference on Intelligent Systems Design and Applications (pp. 177-181). IEEE. <https://doi.org/10.1109/ISDA.2013.6920731>

Bakchy, S. C., Peyal, H. I., Islam, M. I., Yeamin, G. K., Miraz, S., & Abdal, M. N. (2023, September). A lightweight-CNN model for efficient lung cancer detection and Grad-CAM visualization. In 2023 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD) (pp. 254-258). IEEE. <https://doi.org/10.1109/ICICT4SD59951.2023.10303569>

Brain Trauma Foundation. Traumatic brain injury statistics. (2024). <https://www.braintrauma.org/> Son Erişim: 01.07.2024

Chilamkurthy, S., Ghosh, R., Tanamala, S., Biviji, M., Campeau, N. G., Venugopal, V. K., ... & Warier, P. (2018). Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *The Lancet*, 392(10162), 2388-2396. [https://doi.org/10.1016/S0140-6736\(18\)31645-3](https://doi.org/10.1016/S0140-6736(18)31645-3)

Choi, J. W., Cho, Y. J., Ha, J. Y., Lee, Y. Y., Koh, S. Y., Seo, J. Y., Choi, Y. H., Cheon, J., Phi, J. H., Kim, I., Yang, J. & Kim, W. S. (2022). Deep learning-assisted diagnosis of pediatric skull fractures on plain radiographs. *Korean Journal of Radiology*, 23(3), 343-354. <https://doi.org/10.3348/kjr.2021.0449>.

Gençtürk, T. H., Gülağız, F. K., & Kaya, İ. (2023). Derin öğrenme yöntemleri kullanılarak BT taramalarında beyin kanaması teşhisinin karşılaştırmalı bir analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(1), 75-84. <https://doi.org/10.38016/jista.1215025>

Gençtürk, T. H., Gülağız, F. K., & Kaya, İ. (2024). Detection and segmentation of subdural hemorrhage on head CT images. *IEEE Access*, 12, 82235-82246. <https://doi.org/10.1109/ACCESS.2024.3411932>  
Greenberg, M. S. (2010). *Handbook of neurosurgery*. (7th ed.) Thieme. ISBN: 978-1-60406-326-4.

Guo, Y., He, Y., Lyu, J., Zhou, Z., Yang, D., Ma, L., ... & Dai, Q. (2022). Deep learning with weak annotation from diagnosis reports for detection of multiple head disorders: a prospective, multicentre study. *The Lancet Digital Health*, 4(8), e584-e593. [https://doi.org/10.1016/S2589-7500\(22\)00090-5](https://doi.org/10.1016/S2589-7500(22)00090-5)

Han, J., Kamber, M., & Pei, J. (2012). *Data mining concepts and techniques*. (3rd ed.). Waltham: Morgan Kaufmann Publishers.

He, K., Zhang, X., Ren, S., & Sun, J. (2016, June). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition* (pp. 770-778). IEEE. <https://doi.org/10.1109/CVPR.2016.90>

Kaya, İ., Gençtürk, T. H. & Kaya Gülağız, F. (2023). A revolutionary acute subdural hematoma detection based on two-tiered artificial intelligence model. *Ulusal Travma Acil Cerrahi Dergisi*, 29(8), 858–871. PMID: 37563894; PMCID: PMC10560802. <https://doi.org/10.14744/tjtes.2023.76756>

Lin, X., Yan, Z., Kuang, Z., Zhang, H., Deng, X. & Yu L. (2022). Fracture R-CNN: An anchor-efficient anti-interference framework for skull fracture detection in CT images. *Medical Physics*, 49(11), 7179-7192. <https://doi.org/10.1002/mp.15809>

Lin, E., & Yuh, E. L. (2022). Computational approaches for acute traumatic brain injury image recognition. *Frontiers in Neurology*, 13, 791816, 1-25. <https://doi.org/10.3389/fneur.2022.791816>

Maconochie, I. & Ross, M. (2007). Head injury (moderate to severe). *BMJ Clin Evid*, 2007(1210), 1-13, 2007. PMID: 19450357; PMCID: PMC2943769.

Mangrulkar, A., Rane, S. B., & Sunnapwar, V. (2021). Automated skull damage detection from assembled skull model using computer vision and machine learning. *International Journal of Information Technology*, 13, 1785-1790. <https://doi.org/10.1007/s41870-021-00752-5>

Muschelli III, J. (2020). ROC and AUC with a binary predictor: a potentially misleading metric. *Journal of Classification*, 37(3), 696-708. <https://doi.org/10.1007/s00357-019-09345-1>

Sehlikoğlu, K., Türkoğlu, A., Bork, T., & Batbaş, M. (2024). Investigation of fatal traumatic head injuries. *Ulus Travma Acil Cerrahi Derg*, 30(3), 160-166. PMID: 38506383; PMCID: PMC10977496. <https://doi.org/10.14744/tjtes.2024.32463>



Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In Proceedings Of The IEEE International Conference On Computer Vision (pp. 618-626). IEEE. <https://doi.org/10.1109/ICCV.2017.74>

Shan, W., Guo, J., Mao, X., Zhang, Y., Huang, Y., Wang, S., ... & Wang, Y. (2021). Automated identification of skull fractures with deep learning: a comparison between object detection and segmentation approach. *Frontiers in Neurology*, 12, 687931, 1-10. <https://doi.org/10.3389/fneur.2021.687931>

Shao, H., & Zhao, H. (2003, September). Automatic analysis of a skull fracture based on image content. In Third International Symposium on Multispectral Image Processing and Pattern Recognition (pp. 741-746). SPIE. <https://doi.org/10.1117/12.538780>

Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International Conference On Machine Learning (pp. 6105-6114). PMLR. <https://doi.org/10.48550/arXiv.1905.11946>

Tu, Z., Talebi, H., Zhang, H., Yang, F., Milanfar, P., Bovik, A., & Li, Y. (2022, October). MaxVit: Multi-axis vision transformer. In European Conference on Computer Vision (pp. 459-479). Cham: Springer Nature Switzerland. <https://doi.org/10.48550/arXiv.2204.01697>

Türkiye Cumhuriyeti Sağlık Bakanlığı. Health statistics Türkiye, Health statistics yearbook for Türkiye . (2019). <https://www.saglik.gov.tr/TR,84966/saglik-istatistikleri-yilligi-2019-yayinlanmistir.html> Son Erişim: 23.06.2024.

Türkiye Ministry of Health Expert Board in Medicine. Türkiye emergency medicine specialty training curriculum. (2022). <https://tuk.saglik.gov.tr/aciltipmufredatv24doc>. Son Erişim: 23.06.2024.

Wallis, A. & McCoubrie, P. (2011). The radiology report--are we getting the message across?. *Clin Radiol*, 66(11), 1015-1022. <https://doi.org/10.1016/j.crad.2011.05.013>

Wan Zaki, W. M. D., Ahmad Fauzi, M. F., & Besar, R. (2009, November). A new approach of skull fracture detection in CT brain images. In Visual Informatics: Bridging Research and Practice: First International Visual Informatics Conference (pp. 156-167). Springer Berlin Heidelberg.

Wang, H. C., Wang, S. C., Yan, J. L., & Ko, L. W. (2023). Artificial Intelligence model trained with sparse data to detect facial and cranial bone fractures from head CT. *Journal of Digital Imaging*, 36(4), 1408-1418. <https://doi.org/10.1007/s10278-023-00829-6>

Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017, July). Aggregated residual transformations for deep neural networks. In Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition (pp. 1492-1500). IEEE. <https://doi.org/10.1109/CVPR.2017.634>

Yamada, A., Teramoto, A., Otsuka, T., Kudo, K., Anno, H., & Fujita, H. (2016, August). Preliminary study on the automated skull fracture detection in CT images using black-hat transform. In 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 6437-6440). IEEE. <https://doi.org/10.1109/EMBC.2016.7592202>

Yamada, A., Teramoto, A., Kudo, K., Otsuka, T., Anno, H., & Fujita, H. (2018). Basic study on the automated detection method of skull fracture in head ct images using surface selective black-hat transform. *Journal of Medical Imaging and Health Informatics*, 8(5), 1069-1076. <https://doi.org/10.1166/jmihi.2018.2410>

Zaki, W. M. D. W. , Fauzi, M. F. A. & R. Besar. (2008, November) .Automated method of fracture detection in CT brain images. In 2008 3rd International Conference on Intelligent System and Knowledge Engineering (pp. 1156-1160). IEEE. <https://doi.org/10.1109/ISKE.2008.4731105>