

Derin Öğrenme Yöntemlerini Kullanarak Beyin Felcinin Otomatik Olarak Sınıflandırılması

Aykut Diker^{1*}

¹*Mühendislik ve Doğa bilimleri Fakültesi, Yazılım Mühendisliği, Bandırma Onyedi Eylül Üniversitesi, Türkiye*

**(aykutdiker@gmail.com) Başlıca yazarın mail adresi*

Özet – İnme olarak da bilinen beyin felci, dünya çapında önde gelen ölüm ve engelli olma nedenidir. Beyin felcinin erken ve doğru teşhisi, etkili tedavi ve daha iyi hasta sonuçları için çok önemlidir. Son yıllarda, derin öğrenme algoritmaları, farklı beyin felci türlerini doğru bir şekilde sınıflandırmada büyük umut vaat etmektedir. Bu çalışma, beyin felci sınıflandırmasında derin öğrenme tekniklerinin performans karşılaştırmasını sunmaktadır. EfficientNetB0, MobileNet-V2, ResNet18 ve VGG-16 gibi farklı derin öğrenme algoritmalarının performansı sırasıyla karşılaştırılmıştır. Beyin felci imgelerinin sınıflandırılması için yapılan deneysel çalışmalarda, EfficientNetB0, MobileNet-V2, ResNet18 ve VGG-16 derin öğrenme modellerine ait sırasıyla 84.6%, 87.4%, 80.9% ve 92.6% doğruluk değerleri elde edilmiştir. Elde edilen doğruluk değerleri göz önüne alındığında ileride yapılacak çalışmalar için umut verici olduğu görülmüştür.

Anahtar Kelimeler – Beyin Felci, Derin Öğrenme, Sınıflandırma, VGG-16, Resnet18

I. GİRİŞ

İnme, her yıl bildirilen 13 milyondan fazla yeni vaka ve 5 milyon ölümlerle dünya çapında önemli bir ölüm ve hastalık nedenidir [1]. Beyin felcinin doğru teşhisi, etkili tedavi ve daha iyi hasta sonuçları için çok önemlidir. Fiziki muayene ve tıbbi öykü incelemesi gibi geleneksel tanı yöntemleri, beyin felcinin doğru ve zamanında teşhis edilmesi için her zaman yeterli olmayabilir. Son yıllarda makine öğrenimi algoritmaları, görüntüleme verileri, klinik veriler ve genetik veriler dahil olmak üzere çeşitli veri kaynaklarına dayalı olarak farklı beyin felci türlerinin doğru şekilde sınıflandırılması için büyük bir potansiyel göstermiştir [2-3].

Son yıllarda, Evrimsel Sinir Ağları (ESA-Convolutional Neural Networks-CNN) ve Tekrarlayan Sinir Ağları (TSA-Recurrent Neural Networks-RNN) gibi derin öğrenme algoritmaları, Destek Vektör Makineleri (Support Vector Machine-SVM) ve Rastgele Ormanlar (Random Forest) gibi geleneksel makine öğrenme algoritmalarına kıyasla beyin vuruşlarını sınıflandırmada üstün performans göstermiştir. [1-4]. Temel Bileşen Analizi (Principal Component


Analysis -PCA), Doğrusal Diskriminant Analizi (Linear Discriminant Analysis-LDA) ve Özyinelemeli Özellik Eleme (Recursive Feature Elimination-RFE) gibi özellik seçme yöntemlerinin sınıflandırma doğruluğunu iyileştirdiği ve model karmaşıklığını azalttığı gösterilmiştir [5]. Ayrıca, çalışmalar, görüntüleme verileri (CT, MRI ve PET), klinik veriler (belirtiler, tıbbi geçmiş ve demografik veriler) ve genetik veriler dahil olmak üzere farklı türde veri kaynaklarının kullanımını araştırmışlardır. Birden çok veri kaynağının entegrasyonunun sınıflandırma doğruluğunu iyileştirdiği ve tahmin gücünü geliştirdiği gösterilmiştir [1-2].

Bu çalışmada, beyin felci imgelerinin sınıflandırılması derin öğrenme yaklaşımlarının bir performans karşılaştırılmasının sunulması üzerine odaklanılmıştır. Bu amaçla, önceden eğitilmiş ESA modellerinden olan EfficientNet-B0, ResNet18, MobileNet-V2 ve VGG-16 kullanılmıştır. Amaç, beyin felci görüntülerini “Normal” veya “Anormal” olarak sınıflandırmaktır. Aynı zamanda, önerilen çalışmanın ana hedeflerinden biri de beyin felci imgelerini sınıflandırmak için yukarıda bahsedilen en uygun ESA modelini belirlemektir.

Çalışmanın diğer bölümleri şu şekilde organize edilmiştir: Bölüm 2’de çalışmaya konu olan veri seti ve kullanılan yöntemler verilmiştir. Bölüm 3’te ise elde edilen deneysel sonuçlar sunulmuştur. Bölüm 4’te ise sonuç ifadeleri sunulmuştur.

II. MATERYAL VE YÖNTEM

Beyin felci görüntülerinden oluşan veri seti, 130 sağlıklı (normal) ve inme teşhisi konmuş deneğin toplam 2501 bilgisayarlı tomografi görüntüsünü içerir. Veri setindeki tüm resimler 650×650 pikseldir ve JPEG formatındadır. Veri setinde yer alan görüntülerin 1551 adedi sağlıklı kişilere, 950 adedi inmeli hastalara aittir. Örnek beyin felci görüntüleri Şekil 1’de gösterilmiş olup, şeklin ilk satırı herhangi bir sorunu olmayan yani normal olguların görüntülerini, ikinci satırda ise felç görüntüleri yer almaktadır [6].



Şekil 1. (a) Normal ve (b) Felçli beyin örnek görüntüleri.

A. EfficientNet

EfficientNet modeli, Google araştırma ekibinden Tan ve Le tarafından sunulmuştur. Bu araştırmacılar, ESA modelinin ölçekleme bölümünü incelediler. Ardından ağın derinliğini, genişliğini ve çözünürlüğünü ölçeklendirmedeki dengelemenin ağ performansını etkilediğini belirlediler. Bu gözleme dayanarak ağın derinliğinin, genişliğinin ve çözünürlüğünün tüm boyutlarını eşit olarak ölçekleyen yeni bir ölçekleme yöntemi önerdiler. EfficientNet, B0’dan B7’ye kadar 8 modelden oluşur. Model büyüdükçe kullanılan parametre

sayısı ve başarı oranı artar. Yapılan çalışmada, EfficientNet-B0 ESA modeli kullanılmıştır.

B. ResNet

ResNet, ağ eğitimini kolaylaştırmak için artık öğrenme çerçeve modülünü kullanan bir ESA mimarisidir. Bu mimari modelin odaklandığı nokta indirgeme sorunudur. Modelin yeniliği, artık blokların kullanılması ve mimarisindeki derinliktir. Geleneksel bir evrişimsel derin öğrenme modelinde, yığılmış katmanlar, istenen temel haritalamaya uyarken ResNet modeli, bu katmanların artık bir eşlemeye oturmasına izin verir. Bu çalışmada, Resnet-18 ESA modeli kullanılmıştır [6].

C. VGG-16

VGG-16, tüm konvolüsyon katmanları için 3x3 boyutunda bir filtre kullanan ve onu en küçük boyutlu filtre yapan 16 katmanlı bir CNN mimarisidir. Model, 224 x 224 boyutunda bir çözünürlükte RGB görüntülerle beslenir. Görüntünün özelliklerini çıkarmak için bir dizi evrişimli katman kullanılır. Evrişim adımı 1’dir. Her evrişim işleminden sonra, evrişimli katman girişinin uzamsal dolgusu, uzamsal boyutunu sağlamalıdır. Evrişim çıkışı, doğrusal olmayan aktivasyon için kullanılır. Mekansal havuzlamadan beş havuzlama katmanı sorumludur. Maksimum havuzlama için 2x2 boyutunda bir filtre ve adım 2 kullanılır. Birbirini izleyen evrişimli ve maksimum havuzlama katmanlarından sonra üç tam bağlı katman oluşturulur. Softmax katmanı son katmandır [6].

D. MobileNet-V2

MobileNet-V2, sınırlı bilgi işlem kaynaklarına sahip mobil ve gömülü cihazlar için tasarlanmış evrişimli bir sinir ağı mimarisidir. Küçük model boyutu ve hesaplama maliyeti ile yüksek doğruluk elde etmek için derinlemesine ayrılabilir evrişimler, doğrusal darboğazlar, ters artıklar ve kısayol bağlantıları kullanır. MobileNet-V2, bir dizi bilgisayarlı görü görevinde en son teknolojiye sahip performans elde etmiştir ve mobil ve gömülü uygulamalarda yaygın olarak kullanılmaktadır [7].

III. DENEYSEL SONUÇLAR

Yapılan deneysel çalışmalar, iş istasyonu üzerinde 2,60 GHz’de işlemci, 16 GB RAM ve 8 GB RAM NVIDIA RTX 2070 grafik kartı ile gerçekleştirilmiştir. Simülasyon platformu olarak ise MATLAB kullanılmıştır. Ek olarak, beyin felci

imgelerinin ESA modelleri ile yapılan eğitim ve test süresince kullanılan parametreleri Tablo 1’de verilmiştir.

Tablo 1. Çalışmada kullanılan eğitim parametreleri

Parametre	Değer
Mini topluluk boyutu	32
Maksimum dönem	30
Başlangıç öğrenme oranı	1e-4
Optimize yöntemi	sgdm
Momentum	0.90

Beyin felci imgelerine ön işlem uygulanmış olup, yeniden boyutlandırma işlemi yapılmıştır. İlk imgeler gri tonlamalı hale getirilip keskinlik işlemi uygulanmıştır. Ardından ise her bir imge 32x32 boyutlarında ESA modellerinin girişine uygulanmıştır.

Beyin felci imgelerinin sınıflandırılması için yapılan deneysel çalışmada, ESA modellerinin başarımları incelenmiştir. ESA modellerini eğitimi için 10-katlı çapraz doğrulama tekniği kullanılmıştır. Çalışmada, ESA modellerin performanslarını ölçmek için karmaşıklık matrisinden türetilen Duyarlılık (Duy), Özgüllük (Özg) ve Doğruluk (Doğ) gibi ve Alıcı işlem karakteristik (AİK) gibi çeşitli performans ölçütleri kullanılmıştır. Bir karmaşıklık matrisi temel olarak Gerçek pozitif (GP), Yanlış pozitif (YP), Gerçek negatif (GN) ve Yanlış negatif (YN) olan dört endeksten oluşmaktadır.

Performans metriklerinin matematiksel ifadeleri Denklem (1)-(4)’de sırasıyla verilmiştir.

$$Duy = \frac{(GP)}{(GP + GN)} \quad (1)$$

$$Özg = \frac{(GN)}{(GN + GP)} \quad (2)$$

$$Doğ = \frac{(GP + GN)}{(GP + YP + GN + YN)} \quad (3)$$

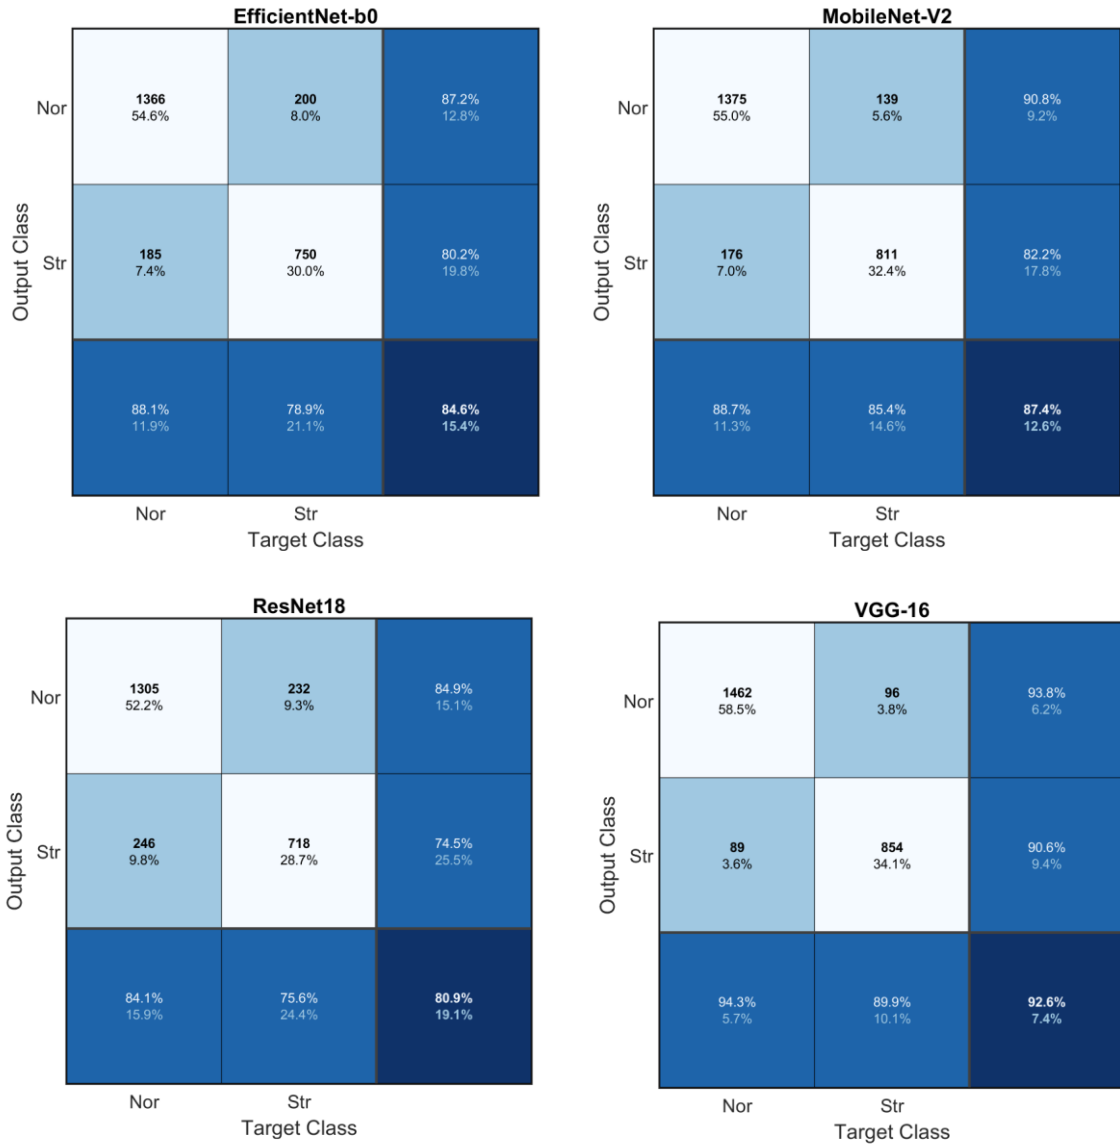
$$F\text{-skor} = \frac{2 * GP}{2 * GP + YP + YN} \quad (4)$$

Şekil 2-3’te ESA mimarilerinin girişine 32x32 boyutlu olarak verilen beyin felci imgelerinin sınıflandırılmasına ait karmaşıklık matrisi ve AİK eğrileri verilmiştir [8-11].

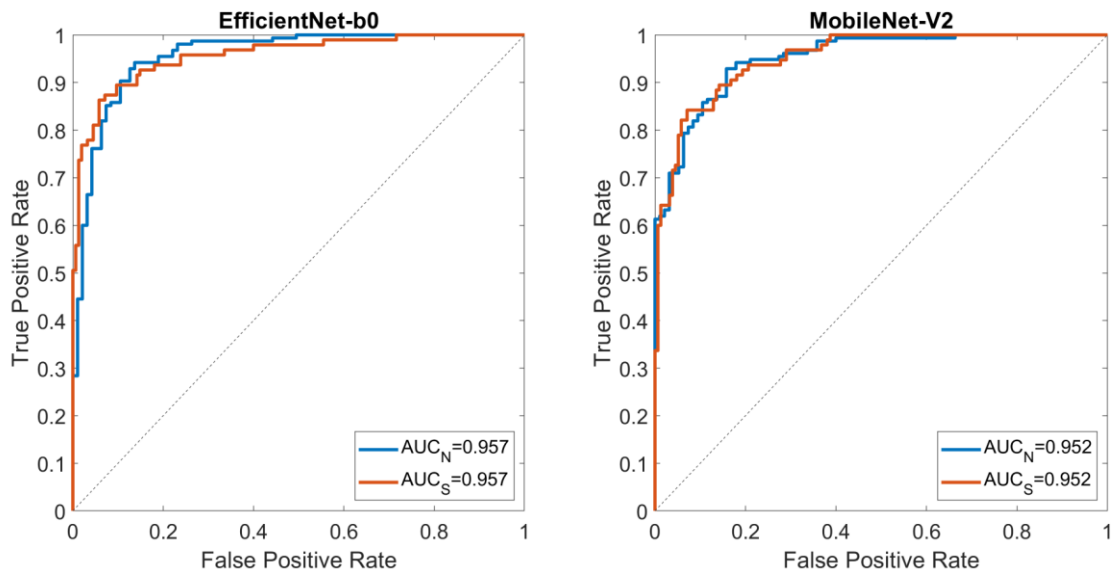
IV. TARTIŞMA

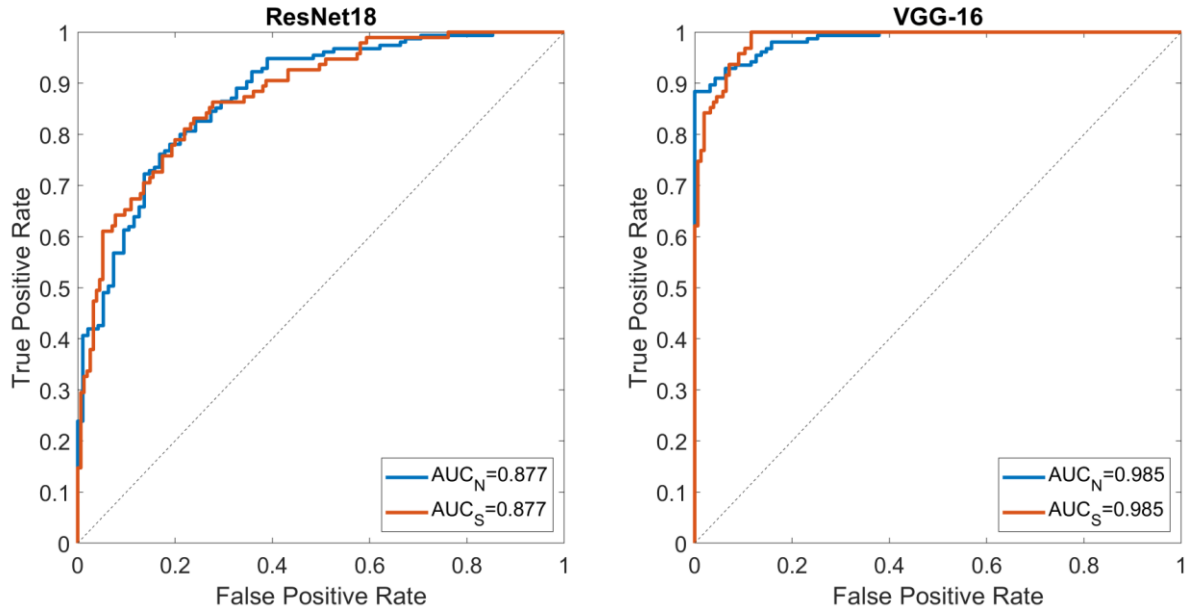
Bu çalışmada, beyin felci imgelerinin sınıflandırılması için çeşitli derin öğrenme tabanlı sınıflandırma yaklaşımlarının performans karşılaştırılması sunulmuştur. Bu bildiride sunulan tüm sınıflandırma algoritmaları, genel doğruluk ve EAA açısından minimum performans sırasıyla 85.86% ve 0.9350 olmak üzere nispeten iyi performans göstermiştir. Ayrıca, bu algoritmaların hesaplama (bellek ve zaman) açısından çok süre alması ve daha çok bellek miktarına ihtiyaç duydukları gözlemlenmiştir. Beyin felci imgelerini sınıflandırmak için ESA tabanlı mimarilerin uygulanmasının umut verici sonuçlar verdiği gözlemlenmiştir. Sonuç olarak, beyin felci imgelerinin sınıflandırılmasında, sırasıyla , EfficientNetB0, MobileNet-V2, ResNet18 ve VGG-16 derin öğrenme modellerine ait sırasıyla 84.6%, 87.4%, 80.9% ve 92.6% performans değerleri elde edilmiştir. ESA modelleri performans değerleri olarak en iyi sınıflandırma sonucu, VGG-16 ESA modeli ile edilmiştir.

İleriki çalışmalarda ise, beyin felci imgelerinin çalışmaları daha derinlemesine irdelenecektir. Bu kapsamda, literatür çalışmaları derinlemesine incelenip, yeni bir ESA modeli sunulması amaçlanmaktadır.



Şekil 2. Karmaşıklık matrisi.





Şekil 3. EAA eğrileri.

KAYNAKLAR

- [1] Feigin. VL, Roth. GA, Naghavi. M, Parmar. P, Krishnamurthi R. Chugh S. Mensah GA, Norrving .B, Shiue I, Ng M, Estep K, Cercy K, Murray CJL, Forouzanfar MH; *Global Burden of Diseases, Injuries and Risk Factors Study 2013 and Stroke Experts Writing Group. Global burden of stroke and risk factors in 188 countries, during 1990-2013: a systematic analysis for the Global Burden of Disease Study 2013.* Lancet Neurol. 2016.
- [2] Heo. J, Yoon. JG, Park. H, et al. Machine Learning-Based Model for Prediction of Outcomes in Acute Stroke. *Stroke.* 50(5):1263-1265, 2019.
- [3] Pitchai. R, Dappuri. B, Pramila. P. V, Vidhyalakshmi. M, Shanthi. S, Alonazi. W. B, ... & Beyene. I. *An Artificial Intelligence-Based Bio-Medical Stroke Prediction and Analytical System Using a Machine Learning Approach.* Computational Intelligence and Neuroscience, 2022.
- [4] Rahman. S, Hasan. M, & Sarkar. A. K. *Prediction of Brain Stroke using Machine Learning Algorithms and Deep Neural Network Techniques.* European Journal of Electrical Engineering and Computer Science, 7(1), 23-30, 2023.
- [5] Chen. J, Chen. L, Zuo. Z, et al. *Prediction of Hemorrhagic Transformation in Acute Ischemic Stroke Based on CT Texture Analysis and Support Vector Machine.* Front Neurol. 2019.
- [6] Diker. A, Elen. A, & Subasi. A. *Brain stroke detection from computed tomography images using deep learning algorithms.* In Applications of Artificial Intelligence in Medical Imaging (pp. 207-222). Academic Press 2023.
- [7] Sandler. M, Howard. A, Zhu, M, Zhmoginov. A, & Chen. L. *MobileNetV2: Inverted Residuals and Linear Bottlenecks.* Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [8] Elen. A, Diker. A, & Subasi. A. *Brain hemorrhage detection using computed tomography images and deep learning.* In Applications of Artificial Intelligence in Medical Imaging (pp. 283-303). Academic Press, 2023.
- [9] Diker. A, *A Performance Comparison of Pre-trained Deep Learning Models to Classify Brain Tumor.* In IEEE EUROCON 2021-19th International Conference on Smart Technologies (pp. 246-249). IEEE, 2021.
- [10] Dönmez. E, *Enhancing classification capacity of CNN models with deep feature selection and fusion: A case study on maize seed classification.* Data & Knowledge Engineering, 141, 102075, 2022.
- [11] Elen. A, *Covid-19 detection from radiographs by feature-reinforced ensemble learning.* Concurrency and Computation: Practice and Experience, 34(23), e7179, 2022.