

Tıbbi BT Görüntülerinde Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Etkinlik Değerlendirmesi: EfficientNet-v2_L'nin Üstün Performansı

Abdulhak ALASULU^{1*}, Yahya DOĞAN², Cüneyt ÖZDEMİR³

¹Computer Engineering / Graduate School of Natural and Applied Sciences, Siirt University, Turkey

²Computer Engineering / Faculty of Engineering and Architecture, Siirt University, Turkey

³Computer Engineering / Faculty of Engineering and Architecture, Siirt University, Turkey

*(aalasulu73@gmail.com)
(yahyadogan@siirt.edu.tr)
(cuneytozdemir33@gmail.com)

(Received: 12 September 2025, Accepted: 21 September 2025)

(2nd International Conference on Pioneer and Academic Research ICPAR 2025, September 15-16, 2025)

ATIF/REFERENCE: Alasulu, A., Doğan, Y. & Özdemir, C. (2025). Tıbbi BT Görüntülerinde Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Etkinlik Değerlendirmesi: EfficientNet-v2_L'nin Üstün Performansı, *International Journal of Advanced Natural Sciences and Engineering Researches*, 9(9), 94-100.

Özet-Bu çalışma, bilgisayarlı tomografi (BT) görüntülerindeki anatomik yapıların otomatik segmentasyonu için dört farklı derin öğrenme (DL) modelinin performanslarını karşılaştırmayı amaçlamaktadır. BT görüntüleme, tanı, cerrahi planlama ve radyoterapi gibi birçok tıbbi alanda kritik öneme sahiptir. Geleneksel manuel segmentasyon yöntemlerinin zaman alıcı, öznel ve değişkenlik gösteren yapısı, otomatik yöntemlere olan ihtiyacı artırmaktadır. Son yıllardaki derin öğrenme, özellikle evrişimli sinir ağları (CNN'ler), görüntü işlemede önemli başarılar elde etmiştir.

Bu çalışmada CT Medical Images veri seti kullanılarak DenseNet-121, EfficientNet-V2_L, MobileNet-V3 ve ResNet-18 modelleri test edilmiştir. Modellerin eğitimi için Adam iyileştirici kullanılmış ve öğrenme oranı dinamik olarak ayarlanmıştır. Modelin genelleme performansını değerlendirmek amacıyla doğrulama kaybı, doğruluk, F1 skoru, kesinlik ve duyarlılık gibi metrikler izlenmiştir.

DeneySEL sonuçlar, incelenen dört model arasında EfficientNet-V2_L'nin en yüksek performansı sergilediğini göstermektedir. Bu model, %95 doğruluk ve %94.74 F1 skoru elde etmiştir.

Bu çalışma, BT görüntülerinin yorumlanmasında insan gücünü azaltma ve farklı yorumlamaların önüne geçme potansiyeli taşıyan otomatik segmentasyon yöntemlerinin önemini vurgulamaktadır. Elde edilen bulgular, özellikle EfficientNet-V2_L modelinin, tıbbi görüntü analizinde yüksek doğrulukta otomatik segmentasyon için uygun bir çözüm olduğunu ortaya koymuştur.

Anahtar Kelimeler –Derin Öğrenme, Bilgisayarlı Tomografi, Makine Öğrenmesi, Model, Performans.

I. GİRİŞ

Tomografi kelimesi Yunancada dilim veya bölüm anlamına gelen tomos ve açıklama anlamına gelen graphia kelimelerinden türemiştir. Bilgisayarlı tomografi taraması, insan vücudu hakkında yapısal ve işlevsel bilgi elde etmek için X ışınlarını kullanan bir görüntüleme yöntemidir. Bilgisayarlı tomografi görüntüsü, yeniden yapılandırılmış görüntüdür ve X ışını emilim profiline dayanarak yeniden oluşturulur. X ışınları elektromanyetik dalgalardır ve tüm maddelerin ve dokuların X ışınlarını emme kabiliyetlerinin farklı olması özelliğine dayanarak tanıda kullanılır.[1]

Bilgisayarlı tomografi (bt) görüntüleme, tanı, cerrahi, klinik çalışmalar ve tedavi planlamasını desteklemek amacıyla insan anatomisi hakkında değerli bilgiler sunan, günümüzde en yaygın kullanılan radyografik teknikler arasında yer almaktadır . Bu görüntüleme yöntemleri ile elde edilen verilerin niceliksel yorumlanmasında, anatomik yapıların ve diğer ilgi alanlarının (roi) doğru bir şekilde tanınması ve segmentasyonu kritik bir rol oynamaktadır [2,3]. Özellikle radyoterapi planlaması sırasında, tıbbi görüntülerin doğru segmentasyonu konturlamada önemli bir adımdır. Segmentasyon, bir görüntünün gri seviyesi, renk, doku, parlaklık ve kontrast gibi benzer özelliklere sahip bölgelere ayrılması işlemi olarak tanımlanır ve temel amaçları anatomik yapıyı incelemek, tümör, lezyon gibi ilgi alanlarını belirlemek ve tedavi planlamasına yardımcı olmaktır [5,6,7].

Geleneksel olarak görüntü işleme, uzman radyologlar tarafından yapılan insan yorumu ve manuel açıklamalarla gerçekleştirilmektedir. Ancak, insan yorumu genellikle nitel, öznel olup, gözlemciler arası ve içi değişkenliği nispeten yüksektir. Manuel açıklamalar ise sınırlı yeniden üretilebilirliğe sahip olmakla kalmayıp, aynı zamanda oldukça zaman alıcıdır [8,9]. Bu zorluklar, özellikle klinik görüntü verilerindeki anatomik yapıların görünümündeki büyük çeşitlilik (çoğu durumda anormal), düşük yoğunluklu kontrast, yüksek görüntü gürültüsü ve farklı mekânsal görüntü çözünürlükleri gibi faktörlerle daha da karmaşıklaşmaktadır . Bu tür sorunlar, bilgisayarlı tomografi görüntülerinde karşılaşılan kısmi hacim etkisi, çeşitli artefaktlar (örneğin hareket artefaktları, halka artefaktları) ve sensörlerden kaynaklanan gürültü ile birleşerek segmentasyon sürecini zorlaştırmaktadır [10]

Bu kısıtlamaların üstesinden gelmek ve radyologların yükünü azaltmak amacıyla, daha iyi verimlilik ve güvenilirlik sunacak otomatik görüntü segmentasyon yöntemlerine olan ihtiyaç artmıştır. Son yıllarda yapay zekâ alanındaki temel atılımlardan biri olan derin öğrenme, özellikle görüntü işleme alanında büyük başarılar elde etmiştir. Derin öğrenmenin temel fikri, birden fazla temsil düzeyi keşfetmek ve daha yüksek seviyeli özelliklerin verilerin daha soyut anlamlarını temsil etmesi umuduyla temsilleri otomatik olarak öğrenmektir. Evrişimli sinir ağları (cnn'ler) gibi derin öğrenme mimarileri, görüntü işlemedeki bu başarının temel bileşenlerinden biri haline gelmiştir. Bu tür yaklaşımlar, geleneksel segmentasyon yöntemlerine kıyasla daha iyi verimlilik, genellik ve esneklik vaat etmektedir. Bu çalışma, bilgisayarlı tomografilerin anatomik yapıların otomatik segmentasyonu için derin öğrenme tekniklerinden olan 4 modelin performansları karşılaştırarak incelenen modeller içerisinde en uygun olanını tespit etmeyi amaçlamaktadır.


II. MATERYAL VE YÖNTEMLER

Bu bölümde, veri seti, model ve eğitim ayrıntıları ele alınmaktadır.

A. Veri Seti

CT Medical Images [11] Veri seti, kontrast ve hasta yaşı kullanımıyla ilişkili BT görüntü verilerindeki eğilimleri incelemek için farklı yöntemlerin test edilmesine olanak sağlamak üzere tasarlanmıştır. Temel fikir, bu özelliklerle güçlü bir şekilde ilişkili görüntü dokularını, istatistiksel desenleri ve özellikleri belirlemek ve muhtemelen yanlış sınıflandırıldıklarında (veya şüpheli vakalar, kötü ölçümler veya zayıf kalibre edilmiş makineler olabilecek aykırı değerleri bulduklarında) bu görüntüleri otomatik olarak

sınıflandırmak için basit araçlar oluşturmaktır. Bu veri setinde 100 adet bilgisayarlı tomografi verisi var. Bu verilerden 80 tanesi eğitim geriye kalan 20 tanesi de doğrulama için kullanılmıştır.



Şekil 1. CT Medical Images veri setinden çeşitli görüntüler.

B. Modeller

Bu bölüm, deneysel çalışmalarda kullanılan transfer öğrenme modellerini açıklamaktadır.

DenseNet-121 [12]: Verimli bir özellik çıkarımı ve sınıflandırma mimarisi sunan derin bir model olan DenseNet-121, transfer öğrenme içeren çalışmalarda sıklıkla kullanılmaktadır. DenseNet'in ayırt edici özelliklerinden biri, yoğun bağlantıların (dense connections) kullanılmasıdır. Tipik bir CNN'de her katman yalnızca bir önceki katmana bağlıyken, DenseNet'te her katman kendisinden önceki tüm katmanlara bağlanır. Ayrıca, her yoğun bağlı katman, dar boğaz (bottleneck) yapısını benimseyerek, hesaplama gücü sabit kalırken daha fazla öğrenilebilir parametrenin kullanılmasına olanak tanır. Bu durum, daha hafif ve hesaplama açısından daha verimli bir model elde edilmesini sağlar. Çok sayıda evrişim (convolution) ve havuzlama (pooling) katmanından oluşan yoğun bloklar, birden çok özellik haritasının yakın şekilde ilişkilendirilmesini kolaylaştırır. Yoğun bloklardan sonra ise modelin boyutunu ve hesaplama yükünü azaltmak amacıyla geçiş katmanları (transition layers) kullanılır. Bu katmanlar, modelin derinliği korunurken özellik haritasının boyutunu küçültür.

EfficientNet-V2_L [13]: EfficientNet, ölçeklenebilir ve verimli derin öğrenme modellerinden oluşan bir koleksiyondur. Bu mimaride, ağın derinliği, genişliği ve çözünürlüğünü en üst düzeye çıkarmaya yönelik yenilikler bulunmaktadır. İlk olarak, ölçekleme işlemi; ağın derinliği, genişliği ve çözünürlüğü dikkate alınarak gerçekleştirilmekte, bu sayede farklı boyutlardaki ağların performanslarının daha etkili şekilde karşılaştırılması mümkün olmaktadır. İkinci olarak, tipik ReLU aktivasyon fonksiyonları yerine daha yumuşak bir doğrusal olmayan bir durum sağlayan swish aktivasyon fonksiyonu kullanılmaktadır. Swish, ağı eğitimi hızlandırabilir ve performansını artırabilir. Üçüncü olarak, MobileNetV2'de de kullanılan MBConv blokları bu mimaride yer almaktadır. Bu bloklar, farklı ölçeklerde paralel çalışan birçok dala sahiptir ve bilgi paylaşımını artırmayı hedefler. EfficientNet-v2-I modeli ise, EfficientNet ailesi içinde yüksek düzey bir model olarak konumlanmaktadır.

MobileNet-V3 [14]: MobileNet-V3, yalnızca cep telefonu işlemcileri (CPU'ları) için özel olarak tasarlanmış bir evrişimli sinir ağıdır. Bu optimizasyon, donanım farkındalığına sahip ağ mimarisi araması ile NetAdapt yönteminin birleştirilmesiyle gerçekleştirilmiş, ardından özgün mimari değişikliklerle geliştirilmiştir. Bu gelişmeler şunları içermektedir: (1) tamamlayıcı arama yaklaşımları, (2) mobil ortamlar için ideal olan özel, verimli doğrusal olmayan (nonlinearity) işlev sürümleri ve (3) yenilikçi, verimli bir ağ mimarisi. Ağ mimarisi, MBConv blokları içerisinde sert swish (hard swish) aktivasyon fonksiyonu ve sıkıştırma-uyarma (squeeze-and-excite) modüllerini içermektedir.

ResNet-18[15] Bu model, geleneksel konvolüsyonel ağlarda görülen bozulma problemini çözmek amacıyla tasarlanmıştır. ResNet-18, her birkaç katmanda bir kestirme (shortcut) bağlantı ekleyerek katmanların giriş ile çıkışı arasındaki farkı öğrenmeyi hedefler. Bu sayede ağ, doğrudan karmaşık fonksiyonlar öğrenmek yerine artık fonksiyonları öğrenerek daha hızlı ve kararlı bir şekilde eğitilebilir. 18 katmandan oluşan bu yapı, daha az parametre kullanarak etkili performans sergiler. Yapılan deneylerde, ResNet-18'in klasik 18 katmanlı ağlara göre daha düşük eğitim hatası ve daha iyi genelleme başarısı sağladığı gözlemlenmiştir. Modelin optimize edilebilirliği, kestirme bağlantılar sayesinde artırılmış ve eğitimi kolaylaştırılmıştır. ResNet-18, sınıflandırma, segmentasyon ve nesne tanıma gibi pek çok görsel görevde yaygın olarak tercih edilmektedir.

C. Eğitim Detayları

Model, belirli bir sayıda dönen (epoch) boyunca eğitilmiştir. Bu eğitim sürecinde, modelin tahmin hatalarını en aza indirmek için bir kayıp fonksiyonu ve model parametrelerini optimize etmek için bir en iyileme algoritması Adam [16] kullanılmıştır. Modelin genelleme performansını ve aşırı öğrenme (overfitting) durumunu izlemek amacıyla, her dönem sonunda doğrulama veri kümesi (val_loader) üzerinde çeşitli metrikler hesaplanmıştır. Bu metrikler arasında doğrulama kaybı (val_loss), doğrulama doğruluğu (val_acc), doğrulama F1 skoru), doğrulama kesinliği ve doğrulama duyarlılığı bulunmaktadır.

Eğitim esnasında, öğrenme oranını dinamik olarak ayarlamak için bir zamanlayıcı kullanılmış ve bu zamanlayıcı, doğrulama kaybındaki değişime göre öğrenme oranını güncellemiştir. Bu yaklaşım, modelin daha stabil ve etkin bir şekilde öğrenmesine yardımcı olur. Ayrıca, eğitim boyunca elde edilen doğrulama F1 skorları takip edilmiş ve en yüksek F1 skorunu veren model durumu, en iyi model olarak kaydedilmiştir. Bu sayede, doğrulama seti üzerinde en iyi performansı gösteren model konfigürasyonu korunmuştur. Eğitim, epoksi ile belirlenen tüm dönemler tamamlanana kadar devam etmiş ve sonrasında en iyi doğrulama F1 skoru raporlanmıştır.


III. DENEY

Bu bölümde, BT tespiti için transfer öğrenme modellerinin performansları CT Medical Images veri seti üzerinde incelenmiştir .Bu bağlamda, farklı kapasitelere sahip modeller aynı eğitim parametreleri kullanılarak karşılaştırılmaktadır. Çalışmanın amacı, CT Medical Images veri seti için en yüksek performansı veren modeli tespit etmektir. Her modelin doğruluk değerleri ve parametre boyutları Tablo 1'de gösterilmiştir.


Tablo 1. Transfer öğrenme modellerinin doğruluk ve F1 skor verileri açısından karşılaştırılması.

Models	Accuracy	F1 Skor
ResNet-18	% 90,00	% 90,00
EfficientNet-v2_1	% 95,00	% 94,74
DenseNet-121	% 80,00	% 80,00
MobileNet-V3	% 80,00	% 80,00


Tablo incelendiğinde EfficientNet-v2_1 modelinin daha yüksek performans gösterdiği ortaya çıkmıştır. Aşağıda EfficientNet-v2_1 modelin sonuçlarını gösteren şekil 2, şekil 3 , şekil 4 ve şekil 5 ten oluşan grafikler var.




Şekil 2 EfficientNet-v2_1 modeli için Confusion Matrixi



Şekil 4 EfficientNet-v2_1 modeli için kayıp grafiği



Şekil 3 EfficientNet-v2_1 modeli için doğruluk grafiği



Şekil 5 EfficientNet-v2_1 modeli için F1 skoru, doğrulama precision ve doğrulama recall grafiği

IV. SONUÇ VE BULGULAR

Bu çalışmada, bilgisayarlı tomografi (BT) görüntülerindeki anatomik yapıların otomatik segmentasyonu için DenseNet-121, EfficientNet-V2_L, MobileNet-V3 ve ResNet-18 olmak üzere dört farklı derin evrişimli sinir ağı (CNN) modelinin performansı karşılaştırıldı. CT Medical Images veri seti üzerinde gerçekleştirilen deneysel çalışmalarda, en iyi performansın EfficientNet-V2_L modeli tarafından elde edildiği tespit edildi. Bu model, %95'lik etkileyici bir doğruluk oranı ve %94.74'lük bir F1 skoru ile diğer modellere kıyasla üstün bir başarı sergiledi.

Elde edilen bu sonuçlar, derin öğrenme tekniklerinin BT görüntülerinin yorumlanmasında insan gücünü önemli ölçüde azaltma potansiyelini bir kez daha ortaya koymaktadır. Ayrıca, farklı radyologlar arasındaki olası yorumlama farklılıklarının önüne geçilerek, tanı ve tedavi planlama süreçlerinde daha standart ve güvenilir sonuçlar elde edilmesine katkı sağlanabilir. Özellikle EfficientNet-V2_L gibi yüksek

performanslı modellerin kullanımı, tıbbi görüntü analizinde otomasyonun ve doğruluğun artırılmasına yönelik önemli bir adım olarak değerlendirilmektedir.

KAYNAKLAR

- [1]- Prince JL, Links JM. Medical imaging signals and system Pearson Education. 2006
- [2]. Doi K. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. Comput Med Imaging Graph. 2007;31:198–211.
- [3]. Giger ML, Karssemeijer N, Schnabel JA. Breast image analysis for risk assessment, detection diagnosis, and treatment of cancer. Annu Rev Biomed Eng. 2013;15:327–357.
- [4]. Withey DJ, Koles ZJ. Three generations of medical image segmentation: Methods and available software. Int J Bioelectromag2007;9:67-8.
- [5]. Gonzalez RC, Woods RE. Digital image processing. 2nd ed. Pearson Education 2004.
- [6]. Pratt KW. Digital image processing. 3rd ed. Willey; 2001. p. 551-87 .13 Journal of Medical Physics, Vol. 35, No. 1, 2010
- [7]. Pal NR, Pal SH. A review on image segmentation techniques. Pattern Recog 1993;26:1277-94.
- [8] Doi K. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. Comput Med Imaging Graph.2007;31:198–211.
- [9]. Giger ML, Karssemeijer N, Schnabel JA. Breast image analysis for risk assessment, detection diagnosis, and treatment of cancer. Annu Rev
- [10] L.P. Clarke, et al., “MRI segmentation: Methods and applications,” Magn. Reson. Imaging, vol. 13, no. 3, pp. 343-368, 1995.
- [11] Albertina, B., Watson, M., Holback, C., Jarosz, R., Kirk, S., Lee, Y., ... Lemmerman, J. (2016). Radiology Data from The Cancer Genome Atlas Lung Adenocarcinoma [TCGA-LUAD] collection. The Cancer Imaging Archive. <http://doi.org/10.7937/K9/TCIA.2016.JGNIHEP5>
- [12] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q., “Densely connected convolutional networks,” In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 4700-4708, 2017.
- [13] Tan, M., & Le, Q., “Efficientnet: Rethinking model scaling for convolutional neural networks,” In International conference on machine learning, pp. 6105-6114, 2019.
- [14]Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H., “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” arXiv preprint arXiv:1704.04861, 2017.
- [15]He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR) (pp. 770–778).
- [16] Kingma, D. P., & Ba, J., “Adam: A method for stochastic optimization” arXiv preprint arXiv:1412.6980, 2014.