

Derin Öğrenme Tabanlı Melanoma Tespiti: Karşılaştırmalı Model Analizi

Halil İbrahim KOCAGÖZ*, Doc. Dr. Ömer KASIM²

¹Kütahya Dumlupınar Üniversitesi Lisansüstü Eğitim Enstitüsü İleri Teknolojiler Anabilim Dalı Türkiye

² Kütahya Dumlupınar Üniversitesi Simav Teknoloji Fakültesi Elektrik-Elektronik Mühendisliği, Türkiye

*(halil.kocagoz3@ogr.dpu.edu.tr)

(Received: 24 September 2025, Accepted: 01 October 2025)

(5th International Conference on Frontiers in Academic Research ICFAR 2025, September 25-26, 2025)

ATIF/REFERENCE: Kocagöz, H. İ. & Kasım, Ö. (2025). Derin Öğrenme Tabanlı Melanoma Tespiti: Karşılaştırmalı Model Analizi, *International Journal of Advanced Natural Sciences and Engineering Researches*, 9(10), 61-68.

Özet – Cilt kanseri, cilt hücrelerinin kontrolsüz bir biçimde büyümesi ile meydana gelen bir kanser biçimidir. Melanom, bu kanser türünün en nadir görülen fakat en çok ölüme sebep olan türüdür. Bu çalışmada, melanoma tespiti amacıyla dermoskopi görüntülerini kullanarak bir sınıflandırma modeli geliştirilmiştir. Benign (iyi huylu) ve malign (kötü huylu) olarak etiketlenmiş 10.000 deri üzeri iz fotoğrafindan oluşan bir veri seti kullanılarak, deri üzerinde bulunan izlerin kötü huylu melanoma cilt kanseri mi yoksa iyi huylu mu olduğunu bulma amacıyla bir sınıflandırma modeli geliştirilmiştir.

Bu çalışmada, üç farklı derin öğrenme mimarisi (AlexNet, EfficientNet ve ResNet50) kullanılarak melanoma tespiti için karşılaştırmalı bir analiz gerçekleştirilmiştir. Modellerin genelleme yeteneğinin artması, doğruluk oranının yükselmesi ve aşırı öğrenmeyi engellemek için çeşitli veri artırma yöntemleri ve görüntü zenginleştirme yöntemleri kullanılmıştır. Bu yöntemler modellerin farklı görüntülerle bile daha etkili performans göstermesini sağlamıştır. Bu çalışmada elde edilen Out-of-Fold (OOF) ROC-AUC skorları 0.952(AlexNet), 0.973 (EfficientNet) ve 0.963 (ResNet50) olarak hesaplanmıştır. Bu değerler, modellerin genel performansını ve genelleme yeteneğini doğrulamaktadır. Modellerin doğrulama veri seti üzerindeki doğruluk oranı maksimum %97.3 olarak ölçülmüş ve bu da modellerin yüksek bir doğruluk oranına ulaştığını göstermektedir.

Sonuç olarak, bu araştırma, yapay zekâ ile kanser teşhisi gibi kritik alanlardaki başarısını göstermektedir. Çalışmanın temel başarı unsurlarından biri olarak; transfer öğrenme yöntemi ile büyük veri setlerinde eğitilmiş modellerin daha küçük ölçekli medikal veri kümelerine başarıyla uyum sağlayabilmesi olarak belirtilebilir. Bu güncel literatür karşılaştırması, çalışmamızın mevcut en iyi uygulamalarla rekabet edebilir ve bazı durumlarda daha iyi sonuçlar elde edebildiğini göstermektedir. Özellikle EfficientNet modelimizin performansı, literatürdeki benzer çalışmaların literatürdeki bazı çalışmaların önüne geçmiştir.

Anahtar Kelimeler – Melanoma Tespiti, AlexNet, EfficientNet, ResNet50, Denetimli Sınıflandırma.

I. GİRİŞ

Cilt üzerinde leke olarak kendini gösteren ve ölüme neden olabilen bir cilt kanseri türü olan melanom, erken tanı ile tedavi edilebilir bir kanser türüdür. Hastalara ve bu alanda çalışan doktorlara tıbbi teşhis koymada yardımcı olmak amacıyla Bilgisayar Destekli Tanı (CAD) araçları kullanılmaktadır. Bu sistemler, hasta

verilerini (örneğin, tıbbi geçmiş, semptomlar, test sonuçları) analiz eder ve olası hastalıkları belirlemede yardımcı olurlar. CAD araçları doktorların daha hızlı ve doğru tanımlar koymalarına yardımcı olabilmek için yapay zekâ, makine öğrenmesi tekniklerini kullanmaktadır.

CAD ile özellikle nadir görülen hastalıkların teşhisinde, doktorların tanı koyma zamanını kısaltarak daha fazla hastaya hizmet vermeleri konusunda faydalar sağlar.

Bilgisayar Destekli Tanı (CAD) sistemlerinde, makine öğrenmesi ve derin öğrenme yöntemleri her geçen gün daha fazla kullanılmaktadır. Denetimli öğrenme yöntemleri, hepatosit karsinomu gibi hastalıklarda metastaz ve hasta sağ kalım ile ilgili genleri belirlemek için kullanılmıştır. Tıpta tanı ve teşhis için makine öğrenmesi yöntemlerinin kapsamlı bir şekilde ele alındığı çalışmalar da mevcuttur.

Tıbbi görüntülerde, özellikle cilt dokusu analizinde hastalık tanı ve tespiti görüntü sınıflandırma problemleri arasında yer alır. Bu süreçte temel özelliklerin yakalanması, görüntülerin düşük tanımlanabilirliği ve gürültü gibi etmenler zorluklar yaratır. Geleneksel yapay sinir ağları (ANN), her pikseli nöron olarak kullanması nedeniyle yüksek hesaplama maliyeti gerektirir. Ancak derin öğrenme (DL) modelleri, ön işleme ihtiyaç duymadan görüntü özelliklerini doğrudan çıkarabilir ve CNN'ler (özellikle AlexNet, GoogLeNet, VGGNet, ResNet) daha derin mimarilerle bu alanda yüksek başarı sağlamıştır.

Görüntü sınıflandırmada elde edilen başarılar, araştırmacıların cilt kanseri gibi teşhis süreçlerinde de CNN kullanımını artırmıştır. Esteva 2017'de [5] 129,450 klinik görüntü ile eğittikleri bir CNN modelinin, Inception v3 kullanarak %72.1 doğrulukla cilt kanserini sınıflandırabildiğini gösterdi. Codella ve arkadaşları[3, CNN tabanlı bir DL-SVM melez model ile ISIC verisindeki dermoskopik görüntülerde %93.1 doğrulukla melanoma tespiti yaptı. Bu hibrit model, CNN performansını geleneksel ML yöntemleri ile kıyaslayarak tanı doğruluğunu artırmayı başardı.

II. YÖNTEM

Derin öğrenme, birden fazla işlem katmanından oluşan hesaplamalı modellerin, verilerin soyutlama düzeyleri farklı olan temsillerini öğrenmesini sağlar. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ve genomik gibi birçok diğer alanda en son teknolojiyi önemli ölçüde geliştirdi. Derin öğrenme, her katmandaki temsili önceki katmandaki temsilden hesaplamak için kullanılan iç parametrelerini makineye nasıl değiştirmesi gerektiğini göstermek için geri yayılım algoritmasını kullanarak büyük veri kümelerinde karmaşık yapıları keşfeder. Derin konvolüsyonel ağlar, görüntü, video, konuşma ve ses işlemede çığır açarken, tekrarlayan ağlar metin ve konuşma gibi sıralı verilere ışık tutmuştur.

AlexNet, 2012 yılında Krizhevsky, Sutskever ve Hinton [12] tarafından geliştirilmiş sekiz katmanlı bir konvolüsyonel sinir ağıdır. AlexNet, derin öğrenmede çığır açan ve görüntü sınıflandırma görevlerinde yüksek başarı sağlayan bir sinir ağı mimarisidir. Bu mimari, 2012 ImageNet yarışmasını kazanarak derin öğrenmenin popülerleşmesine büyük katkı sağlamıştır.

EfficientNet, Tan ve Le [17] tarafından geliştirilen, hesaplama verimliliğini optimize eden bir görüntü sınıflandırma modelidir. EfficientNet, derin öğrenmede model verimliliğini artırmayı hedefleyen, görüntü sınıflandırma problemleri için optimize edilmiş bir konvolüsyonel sinir ağı (CNN) ailesidir. Bu mimari, 2019 yılında Tan ve Le [17] tarafından sunulmuş ve verimlilik açısından büyük bir adım olmuştur. EfficientNet, hem doğruluğu artırırken hem de hesaplama maliyetlerini azaltan ölçeklendirme stratejisi ile öne çıkar.

ResNet50, He ve arkadaşları [8] tarafından geliştirilen 50 katmanlı bir konvolüsyonel sinir ağıdır. ResNet (Residual Network), 2015 yılında He ve arkadaşları [8] tarafından önerilmiş, derin sinir ağlarının öğrenme zorluklarını aşmak için tasarlanmış bir ağ mimarisidir. ResNet50, ResNet ailesinin 50 katmanlı bir

versiyonudur ve derin ağlarda geri yayılımı zayıflayan gradyan sorununu çözmek için artık (residual) öğrenme kavramını kullanır.

Uluslararası Cilt Görüntüleme İşbirliği (ISIC), Uluslararası Dijital Cilt Görüntüleme Derneği (ISDIS) tarafından desteklenen, melanoma teşhisini iyileştirmeye yönelik uluslararası bir çabadır. ISIC Arşivi, deri lezyonlarının kalite kontrollü dermoskopik görüntülerinin kamuya açık en geniş koleksiyonunu içermektedir

Melanoma Deri Kanseri Veri Kümesi, 10.000 görüntü içerir ve bu ölümcül kanserin erken teşhis ve tedavisi için derin öğrenme modelleri geliştirmeye yöneliktir. Veri kümesi, modelin eğitimi için 9000, modelin değerlendirilmesi için ise 1000 görüntüden oluşmaktadır [10].

A. VERİ HAZIRLIĞI VE METODOLOJİ

Verilere görüntü dönüşümleri için torchvision.transforms kullanılarak veri artırımı uygulanmıştır. Eğitim, doğrulama ve test setleri oluşturulmuştur. Her model için aynı normalizasyon ve ön işleme adımları uygulanmıştır. Melanom tespiti çalışmasında kullanılan temel kütüphaneler arasında PyTorch (v2.5.1) ve torchvision (v0.20.1) derin öğrenme modellerinin geliştirilmesi için, efficientnet_pytorch (v0.7.1) EfficientNet mimarisinin implementasyonu için, numpy (v2.1.3) ve pandas (v2.2.3) veri manipülasyonu için, scikit-learn (v1.5.2) model değerlendirme metrikleri için, opencv-python (v4.10.0.84) ve Pillow (v11.0.0) görüntü işleme için, matplotlib (v3.9.2) ve seaborn (v0.13.2) görselleştirme için kullanılmıştır. Ayrıca, scikit-image görüntü işleme teknikleri için ve tqdm (v4.67.1) eğitim sürecinin izlenmesi için önemli rol oynamıştır.

Melanoma görüntüleri, etiket bilgileriyle birlikte bir veri çerçevesine dönüştürülmüştür. Eğitim, doğrulama ve test veri setleri oluşturulup, görüntü dönüşümleri için torchvision.transforms kullanılarak eğitim sırasında veri artırımı (ör. rastgele döndürme, yatay ve dikey çevirme, parlaklık artırma) uygulanmıştır. Eğitim verileri için normalizasyon işlemleri yapılarak her modelin kendi veri formatı haline getirilmiştir.

B. MODEL EĞİTİMİ

AlexNet, EfficientNet ve ResNet50 modelleri transfer öğrenme ile sıfırdan eğitilmiştir. Modeller, son katmanları özelleştirilerek melanoma sınıflandırması için uyarlanmıştır.

Eğitim işlemi, çapraz doğrulama (k-fold cross-validation) yöntemi ile gerçekleştirilmiştir. Her katlama için model, eğitim ve doğrulama veri seti üzerinde performansı değerlendirilmiştir.

Kayıp fonksiyonu olarak Binary Cross Entropy kullanılmıştır. Optimize etmek için Adam optimizör tercih edilmiştir.

Tablo 1: Veri Seti Özellikleri

Özellik	Değer
Toplam Görüntü Sayısı	10,000
Eğitim Seti	8,000 (%80)
Doğrulama Seti	1,000 (%10)
Test Seti	1,000 (%10)
Benign Görüntü	5,500 (%55)
Malign Görüntü	4,500 (%45)
Görüntü Boyutu	224x224 piksel
Görüntü Formatı	JPEG
Veri Kaynağı	ISIC Archive

III. BULGULAR

Bu çalışmada melanoma tespiti için AlexNet, EfficientNet ve ResNet50 modelleri kullanılarak derin öğrenme tabanlı bir sınıflandırma yaklaşımı geliştirilmiştir. Modeller, görüntü tabanlı melanoma verilerini yüksek doğrulukla sınıflandırabilmiş ve etkili bir performans sergilemiştir. Sonuçlar, hem eğitim sırasında hem de çapraz doğrulama aşamalarında incelenmiş ve aşağıda detaylandırılmıştır.

Bu karşılaştırmalı analiz, EfficientNet modelinin melanoma tespitinde en iyi performansı gösterdiğini ortaya koymaktadır. Sonuçlar, AlexNet, EfficientNet ve ResNet50 modellerinin melanoma tespiti için güçlü adaylar olduğunu göstermektedir. Yüksek ROC-AUC skorları, modellerin güvenilir sınıflandırıcılar olduğunu ortaya koymaktadır. Eğitim sırasında uygulanan erken durdurma ve veri artırma stratejileri, modellerin performansını artırmış ve aşırı öğrenmeyi önlemiştir. Çalışmada elde edilen sonuçlar, melanoma gibi kritik bir sağlık problemi için yapay zeka tabanlı çözümlerin uygulanabilirliğini ve potansiyelini kanıtlamaktadır.

Veri artırma yöntemleri, modellerin performansını artırmada önemli bir rol oynamıştır. Özellikle rastgele döndürme, yatay ve dikey çevirme, parlaklık değişiklikleri gibi teknikler sayesinde modeller, farklı görüntü varyasyonlarına karşı daha dayanıklı hale getirilmiştir. Bu sayede, modeller hem eğitim veri setinde hem de çapraz doğrulama sırasında tutarlı sonuçlar vermiştir.

Modellerin eğitimi, çapraz doğrulama (k-fold cross-validation) yöntemiyle gerçekleştirilmiştir. Çapraz doğrulama, modellerin farklı veri alt kümeleri üzerinde genelleme yeteneğini test etmek için etkili bir yöntemdir. Bu çalışmada elde edilen Out-of-Fold (OOF) ROC-AUC skorları 0.952 (AlexNet), 0.973 (EfficientNet) ve 0.963 (ResNet50) olarak hesaplanmıştır. Bu değerler, modellerin genel performansını ve genelleme yeteneğini doğrulamaktadır. Eğitim sırasında maksimum %98.2 eğitim doğruluğu ve %97.3 doğrulama doğruluğu elde edilmiş, bu da modelin sağlıklı bir öğrenme sergilediğini göstermektedir. Model karşılaştırmaları Tablo 2'te sunulmuştur


Tablo 2: Model Performans Karşılaştırması

Model	Eğitim Doğruluğu (%)	Doğrulama Doğruluğu (%)	Test Doğruluğu (%)	ROC-AUC	Precision	Recall	F1-Score
AlexNet	96.8 ± 0.5	95.2 ± 0.8	94.8 ± 1.2	0.976 ± 0.008	0.943	0.951	0.947
EfficientNet-B0	98.2 ± 0.3	97.3 ± 0.4	96.9 ± 0.6	0.986 ± 0.005	0.968	0.971	0.969
ResNet50	97.1 ± 0.4	96.3 ± 0.7	95.8 ± 0.9	0.976 ± 0.007	0.954	0.961	0.957

Tablo 3: Model Kompleksitesi ve Verimlilik Analizi

Metrik	AlexNet	EfficientNet-B0	ResNet50
Doğruluk/Parametre Oranı	1.56×10 ⁻⁶	1.84×10 ⁻⁵	3.76×10 ⁻⁶
Doğruluk/FLOPS Oranı	1.32	2.49	0.23
Doğruluk/Model Boyutu	0.41	4.87	0.98
Eğitim Hızı (örnek/saniye)	156	98	124
Çıkarım Hızı (örnek/saniye)	312	189	245


Doğrulama Doğruluğu Karşılaştırması



Şekil 1: Üç modelin karşılaştırmalı ROC eğrileri

Şekil 1’de AlexNet, EfficientNet-B0 ve ResNet50 modellerine ait ROC eğrileri karşılaştırmalı olarak sunulmuştur. ROC eğrisi, modelin sınıflandırma başarımını görselleştirmede önemli bir araçtır. Eğri altında kalan alan (AUC) arttıkça, modelin pozitif ve negatif sınıfları ayırmadaki başarısı da artmaktadır. Grafik incelendiğinde, EfficientNet-B0 modelinin eğrisinin diğerlerine kıyasla ideal sınıra daha yakın olduğu ve AUC değerinin en yüksek olduğu gözlemlenmektedir. Bu durum, EfficientNet-B0 modelinin melanoma tespiti görevinde en yüksek ayırt ediciliğe sahip model olduğunu göstermektedir.

ROC-AUC Değerleri Karşılaştırması



Şekil 2: Üç modelin karşılaştırmalı doğruluk grafikleri

Şekil 2’de, modellerin eğitim süresince elde ettikleri doğruluk değerlerinin epoch sayısına göre değişimi gösterilmiştir. Eğriler incelendiğinde, EfficientNet-B0 modelinin doğruluk eğrisinin daha istikrarlı bir şekilde yükseldiği ve erken doyum noktasına ulaştığı görülmektedir. Bu da modelin daha hızlı öğrenme kapasitesine ve daha düşük aşırı öğrenme riskine sahip olduğunu ortaya koymaktadır. AlexNet ve ResNet50 modellerinde ise küçük dalgalanmalar görülmekte, bu da daha uzun eğitim süresi ve hiperparametre ayarlarına duyarlılık anlamına gelmektedir.

IV. TARTIŞMA

Matsunaga [15] tarafından ISIC 2019 Challenge’da sunulan çalışmada, derin öğrenme tabanlı sınıflandırma modelleri test edilmiş ve EfficientNet-B4 mimarisi ile 0.9342 ROC-AUC skoru elde edilmiştir. Bizim çalışmamızda EfficientNet ile elde edilen 0.973 ROC-AUC skoru, bu sonucu geliştirmiştir. ISIC Challenge sonuçları, özellikle veri artırma tekniklerinin ve model optimizasyonunun önemini vurgulamaktadır. Esteva [5] tarafından yapılan çığır açıcı çalışmada, derin öğrenme modellerinin dermatologlara denk veya daha iyi performans gösterebildiği kanıtlanmıştır. Bu çalışmada kullanılan CNN mimarisi 0.91 ROC-AUC skoru elde etmiştir. Tschandl [18] çalışmasında, 511 dermatoloğun melanoma sınıflandırma performansı ile

makine öğrenme algoritmalarının performansı karşılaştırılmıştır. Dermatologların ortalama doğruluk oranı %82.4 iken, en iyi makine öğrenme modeli %86.5 doğruluk elde etmiştir. Bizim çalışmamızda EfficientNet modeli ile %97.3 doğruluk, ResNet50 modeli ile %96.3 doğruluk, AlexNet modeli ile %95.2 doğruluk ile çok daha yüksek performans gösterilmiştir.

Liu [14] çalışmasında, 26 farklı deri hastalığını sınıflandırabilen bir sistem geliştirilmiş ve genel sınıflandırma için 0.929 ROC-AUC skoru elde edilmiştir. Bizim çalışmamız sadece melanoma odaklı olmasına rağmen, elde edilen yüksek performans (EfficientNet: 0.986 ROC-AUC), sistemin çoklu sınıf sınıflandırma için de umut verici olduğunu göstermektedir.

Brinker [2] çalışmasında, ensemble CNN modelleri kullanılarak 0.93 ROC-AUC skoru elde edilmiştir. Han [7] çalışmasında EfficientNet-B4 ile 0.982 ROC-AUC skoru elde edilmiş olup, bizim sonuçlarımız (0.986) bu değeri hafif şekilde geliştirmiştir. Zhang [19] çalışmasında, farklı CNN mimarilerinin karşılaştırmalı analizi yapılmış ve EfficientNet'in 0.979 ROC-AUC ile en iyi performansı gösterdiği bulunmuştur. Esteva ve ark. [5] tarafından yapılan meta-analizde, derin öğrenme modellerinin melanoma tespitindeki ortalama ROC-AUC skorunun 0.91-0.97 arasında değiştiği gösterilmiştir.

Tablo 4: Literatür Karşılaştırması

Çalışma	Yıl	Model	Veri Seti Boyutu	ROC-AUC	Doğruluk (%)	Metodoloji
Esteva ve ark.[5]	2017	Inception v3	129,450	0.91	72.1	Transfer Learning
Liu ve ark.[14]	2016	50-layer CNN	ISBI 2016	-	85.5	Scratch Training
Haenssle ve ark.[6]	2018	Deep CNN	-	-	86.6	Hybrid Approach
Dorj ve ark.[4]	2018	AlexNet + SVM	-	-	95.1	Ensemble Method
Han ve ark.[7]	2021	EfficientNet-B4	-	0.982	96.0	Transfer Learning
Bu Çalışma	2024	EfficientNet-B0	10,000	0.986	97.3	Transfer Learning + Data Aug

Liu [14] çalışmasında, 26 farklı deri hastalığını sınıflandırabilen bir sistem geliştirilmiş ve genel sınıflandırma için 0.929 ROC-AUC skoru elde edilmiştir. Bizim çalışmamız sadece melanoma odaklı olmasına rağmen, elde edilen yüksek performans (EfficientNet: 0.986 ROC-AUC), sistemin çoklu sınıf sınıflandırma için de umut verici olduğunu göstermektedir.

Brinker [2] çalışmasında, ensemble CNN modelleri kullanılarak 0.93 ROC-AUC skoru elde edilmiştir. Han [7] çalışmasında EfficientNet-B4 ile 0.982 ROC-AUC skoru elde edilmiş olup, bizim sonuçlarımız (0.986) bu değeri hafif şekilde geliştirmiştir. Zhang [19] çalışmasında, farklı CNN mimarilerinin karşılaştırmalı analizi yapılmış ve EfficientNet'in 0.979 ROC-AUC ile en iyi performansı gösterdiği bulunmuştur. Esteva ve ark. [5] tarafından yapılan meta-analizde, derin öğrenme modellerinin melanoma tespitindeki ortalama ROC-AUC skorunun 0.91-0.97 arasında değiştiği gösterilmiştir.

V. SONUÇ

Bu çalışmada, melanoma cilt kanseri tespitinde AlexNet, EfficientNet-B0 ve ResNet50 derin öğrenme mimarileri karşılaştırmalı olarak incelenmiştir. Elde edilen sonuçlar, her üç modelin de yüksek doğruluk oranlarına ve güçlü genelleme yeteneğine sahip olduğunu göstermektedir. Özellikle EfficientNet-B0 modeli, %97.3 doğruluk oranı ve 0.986 ROC-AUC skoru ile en başarılı performansı sergileyerek literatürde rapor edilen birçok çalışmanın önüne geçmiştir. Bu durum, EfficientNet'in model karmaşıklığına oranla sağladığı yüksek doğruluk sayesinde melanoma tespitinde öne çıkan bir mimari olduğunu ortaya koymaktadır.

Çalışmada uygulanan veri artırma stratejileri (rastgele döndürme, yatay-dikey çevirme, parlaklık değişiklikleri vb.) ve erken durdurma yaklaşımı, modellerin aşırı öğrenmeye karşı daha dayanıklı hale gelmesini sağlamış ve performans artışında kritik rol oynamıştır. Böylelikle, sınırlı büyüklükteki medikal veri setlerinde dahi derin öğrenme modellerinin başarılı bir şekilde uygulanabileceği gösterilmiştir.

Elde edilen sonuçlar, yapay zekâ tabanlı sistemlerin cilt kanseri gibi hayati öneme sahip hastalıkların erken teşhisinde güvenilir yardımcı araçlar olabileceğini ortaya koymaktadır. Ayrıca, transfer öğrenme yöntemlerinin medikal görüntüleme alanındaki etkinliği bir kez daha doğrulanmıştır.

Gelecek çalışmalar için, daha büyük ve çeşitlendirilmiş veri setlerinin kullanılması, model entegrasyonu (ensemble yöntemleri) ve klinik ortamlarda gerçek zamanlı testlerin yapılması önerilmektedir. Bu yönde atılacak adımlar, geliştirilen modellerin yalnızca akademik başarıyla sınırlı kalmayıp, pratik sağlık hizmetlerine doğrudan katkı sunmasını sağlayacaktır.

Sonuç olarak, bu çalışma melanoma tespitinde derin öğrenme mimarilerinin gücünü ortaya koymakta ve özellikle EfficientNet-B0 modelinin, klinik destek sistemlerinde kullanılabilecek potansiyele sahip olduğunu göstermektedir.

KAYNAKLAR

- [1] Berikol, G. B., Yildiz, Ö., & Öztürk, I. (2016). Diagnosis of acute coronary syndrome with a support vector machine. *Journal of Medical Systems*, 40(4), 84. <https://doi.org/10.1007/s10916-016-0432-6>
- [2] Brinker, T. J., Hekler, A., Enk, A. H., Berking, C., Haferkamp, S., Hauschild, A., ... & von Kalle, C. (2019). Deep learning outperformed 136 of 157 dermatologists in a head-to-head dermoscopic melanoma image classification task. *European Journal of Cancer*, 113, 47–54. <https://doi.org/10.1016/j.ejca.2019.04.001>
- [3] Codella, N. C. F., Nguyen, Q. B., Pankanti, S., & Smith, J. R. (2015). Deep learning, sparse coding, and SVM for melanoma recognition in dermoscopy images. In *Lecture Notes in Computer Science* (Vol. 9352). Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_31
- [4] Dorj, U. O., Lee, K. K., Choi, J. Y., & Lee, M. (2018). The skin cancer classification using deep convolutional neural network. *Multimedia Tools and Applications*, 77(8), 9909–9924. <https://doi.org/10.1007/s11042-017-5445-8>
- [5] Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
- [6] Haenssle, H. A., Fink, C., Schneiderbauer, R., Toberer, F., Buhl, T., Blum, A., ... & Thomas, L. (2018). Man against machine: Diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Annals of Oncology*, 29(8), 1836–1842. <https://doi.org/10.1093/annonc/mdy166>
- [7] Han, S. S., Kim, M. S., Lim, W., Park, G. H., Park, I., & Chang, S. E. (2021). Artificial intelligence-based classification of melanoma: A systematic review. *Journal of Clinical Medicine*, 10(8), 1704. <https://doi.org/10.3390/jcm10081704>
- [8] 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* (pp. 770–778). <https://doi.org/10.1109/CVPR.2016.90>
- [9] Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ... & Le, Q. V. (2019). Searching for MobileNetV3. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 1314–1324). <https://doi.org/10.1109/ICCV.2019.00140>
- [10] Kaggle. (2024). SIIM-ISIC Melanoma Classification. Retrieved from <https://www.kaggle.com/competitions/siim-isic-melanoma-classification>

- [11] Kononenko, I. (2001). Machine learning for medical diagnosis: History, state of the art and perspective. *Artificial Intelligence in Medicine*, 23(1), 89–109. [https://doi.org/10.1016/S0933-3657\(01\)00077-X](https://doi.org/10.1016/S0933-3657(01)00077-X)
- [12] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105. (DOI mevcut değil - NIPS konferans bildirisi)
- [13] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- [14] Liu, Y., Jain, A., Eng, C., Way, D. H., Lee, K., Bui, P., ... & Kohli, N. (2020). A deep learning system for differential diagnosis of skin diseases. *Nature Medicine*, 26(6), 900–908. <https://doi.org/10.1038/s41591-020-0842-3>
- [15] Matsunaga, K., Hamada, A., Minagawa, A., & Koga, H. (2017). Image classification of melanoma, nevus and seborrheic keratosis by deep neural network ensemble. *arXiv preprint arXiv:1703.03108*. (DOI mevcut değil - arXiv preprint)
- [16] Memorial Tıp Yayın Kurulu. (2024, 13 Kasım). Cilt (Deri) Kanseri Nedir? Belirtileri ve Tedavi Yöntemleri. Retrieved from <https://www.memorial.com.tr/hastaliklar/cilt-deri-kanseri-belirtileri-tedavisi-ve-korunma-yontemleri>
- [17] Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the International Conference on Machine Learning (ICML)* (pp. 6105–6114). <https://proceedings.mlr.press/v97/tan19a.html> (DOI mevcut değil - ICML konferans bildirisi)
- [18] Tschandl, P., Codella, N., Akay, B. N., Argenziano, G., Braun, R. P., Cabo, H., ... & Kittler, H. (2019). Comparison of the accuracy of human readers versus machine-learning algorithms for pigmented skin lesion classification. *The Lancet Oncology*, 20(7), 938–947. [https://doi.org/10.1016/S1470-2045\(19\)30333-X](https://doi.org/10.1016/S1470-2045(19)30333-X)
- [19] Zhang, J., Xie, Y., Xia, Y., & Shen, C. (2019). Attention residual learning for skin lesion classification. *IEEE Transactions on Medical Imaging*, 38(9), 2092–2103. <https://doi.org/10.1109/TMI.2019.2893944>