

Atf İçin: Aruk, I. ve Toprak, A. N. (2025). Cilt Kanseri Tanısı için Farklı Evrişimsel Sinir Ağı Modellerinin Karşılaştırılması. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(1), 25-38.

To Cite: Aruk, I. & Toprak, A. N. (2025). A Comparison of Different Convolutional Neural Network Models for Skin Cancer Diagnosis. *Journal of the Institute of Science and Technology*, 15(1), 25-38.

Cilt Kanseri Tanısı için Farklı Evrişimsel Sinir Ağı Modellerinin Karşılaştırılması

İbrahim ARUK^{1*}, Ahmet Nusret TOPRAK¹

Öne Çıkanlar:

- Derin öğrenme ile cilt kanseri sınıflandırılması
- CNN modelleri kapsamlı bir şekilde karşılaştırılması
- EfficientNet-b0 modeli ile %84.00 doğruluk sağlanması

Anahtar Kelimeler:

- Cilt kanseri sınıflandırması
- Evrişimsel sinir ağları
- Melanom

ÖZET:

Son yıllarda, dünya genelinde cilt kanseri görülme oranında önemli bir artış gözlemlenmektedir. Cilt kanserinin zamanında ve doğru bir şekilde teşhis edilmesi, tedavi başarı oranlarını artırmakta ve aynı zamanda hastaların yaşam kalitesinin iyileşmesine büyük katkı sağlamaktadır. Geleneksel cilt kanseri tanı yöntemleri genellikle görsel değerlendirmelere dayanmakta ve öznel bir yaklaşım içermektedir. Bununla birlikte, derin öğrenme algoritmaları, cilt kanseri teşhislerinin doğruluğunu ve verimliliğini artırmak için etkili çözümler sunmaktadır. Bu çalışmada, EfficientNet, VGG, Inception, DenseNet ve DarkNet gibi gelişmiş Evrişimsel Sinir Ağı (CNN) modellerinin cilt kanseri sınıflandırmasındaki performansları incelenmiştir. Toplamda yirmi bir CNN modeli, ISIC 2017 veri seti üzerinde, veri artırma ve transfer öğrenme teknikleri kullanılarak eğitilmiş ve detaylı bir şekilde değerlendirilmiştir. Deneysel sonuçlar, EfficientNet-b0 modelinin %84.00 doğruluk, %83.63 kesinlik, %74.96 duyarlılık ve %78.59 F1-skoru ile en yüksek performansı sergilediğini göstermiştir. Bu kapsamlı analiz, CNN tabanlı modellerin cilt kanseri teşhisindeki etkinliğini göstermekte ve gelecekteki araştırmalar için bu algoritmaların potansiyelini ortaya koymaktadır.

A Comparison of Different Convolutional Neural Network Models for Skin Cancer Diagnosis

Highlights:

- Skin cancer classification with deep learning
- A comprehensive comparison of CNN models
- Achieving 84.00% accuracy with EfficientNet-b0 model

Keywords:

- Skin cancer classification
- Convolutional neural networks
- Melanoma

ABSTRACT:

In recent years, a notable rise in the prevalence of skin cancer has been seen worldwide. Early and correct diagnosis of skin cancer improves treatment success rates and substantially enhances patients' quality of life. Traditional skin cancer diagnostic techniques generally depend on visual evaluations and include a subjective methodology. On the other hand, deep learning algorithms provide effective solutions to improve the accuracy and time of skin cancer diagnostics. This study evaluates the efficacy of advanced Convolutional Neural Network (CNN) models, including EfficientNet, VGG, Inception, DenseNet, and DarkNet, in the classification of skin cancer. Twenty-one CNN models were trained and extensively analyzed on the ISIC 2017 dataset utilizing data augmentation and transfer learning methodologies. The results of the study demonstrated that the EfficientNet-b0 model attained superior performance with an accuracy of 84.00%, precision of 83.63%, sensitivity of 74.96%, and an F1-score of 78.59%. This comprehensive study shows the efficacy of CNN-based models in skin cancer diagnosis and illustrates the promise of these algorithms for future research.

¹İbrahim ARUK ([Orcid ID: 0009-0003-7483-4542](https://orcid.org/0009-0003-7483-4542)), Ahmet Nusret TOPRAK ([Orcid ID: 0000-0003-4841-9508](https://orcid.org/0000-0003-4841-9508)), Erciyes Üniversitesi, Bilgisayar Mühendisliği Ana Bilim Dalı, Bilgisayar Mühendisliği Bölümü, Kayseri, Türkiye

*Sorumlu Yazar/Corresponding Author: İbrahim ARUK, e-mail: ibrahimaruk@gmail.com

GİRİŞ

Kanser, sağlıklı hücrelerin anormal bir şekilde hızla değişerek kontrolsüz büyümeye başlaması ile birlikte ortaya çıkmaktadır. Genellikle bu süreç sonunda bir tümör oluşumu meydana gelmektedir (Subramanian ve ark., 2024). Dünya genelinde en yaygın görülen kanser türlerinden birisi cilt kanseridir. Melanom ise cilt kanseri türleri arasında en tehlikeli ve ölümcül olanıdır. Dünya Sağlık Örgütü'ne göre, her yıl dünya genelinde yaklaşık 132.000 yeni melanom vakası teşhis edilmektedir (Wang ve ark., 2024). Sadece Amerika Birleşik Devletleri'nde, 2024 yılında tahmini 100.640 yeni vaka ön görülmeyle birlikte, erkek ve kadın olmak üzere tahmini toplam 8.290 kişinin hayatını kaybedeceği öngörülmektedir (Siegel ve ark., 2024). Cilt kanserinin ortaya çıkması ve yaygınlaşmasının başlıca nedenleri arasında ultraviyole radyasyonu (UV), genetik yatkınlık, sağlıklı yaşam tarzı ve sigara kullanımı yer almaktadır. En baskın neden olan UV, ozon tabakasının hızla incelmesi ve zararlı ışınların dünya yüzeyine ulaşması ile birlikte bu sorunu daha da kötüleştirmektedir (Hameed ve ark., 2024). Tüm bu nedenlerden dolayı cilt kanseri vakaları hızlı bir şekilde artmakta ve insan hayatını ciddi bir biçimde tehdit etmektedir.

Şekil 1'de örnek görüntüleri verilen en yaygın üç cilt kanseri türü, bazal hücreli karsinom (BCC), skuamoz hücreli karsinom (SCC) ve melanom (MEL)'dir. BCC, deri kanserlerinin büyük bir kısmını oluşturmakta ve genellikle cildin üst tabakasındaki bazal hücrelerden kaynaklanmaktadır. Bu kanser türü, genellikle yavaş gelişmekte ve nadiren diğer organlara yayılmaktadır. SCC, daha derin cilt katmanlarında gelişmekte ve BCC'ye göre daha agresif bir seyir izlemektedir. Ayrıca lenf nodlarına yayılma potansiyeline sahiptir. Melanom ise, cildin pigment üretiminden sorumlu melanosit hücrelerinde başlamakta ve diğer iki türden daha hızlı yayılma eğilimindedir. Melanin granül birikimi ve cildin en dış tabakasına yayılması bu duruma neden olmaktadır (Dillshad ve ark., 2023). Melanom, yüksek bir ölüm oranına sahip olmasına rağmen, erken tespit edildiğinde çoğunlukla tedavi edilebilen bir hastalıktır.



Şekil 1. Cilt kanseri türlerine ait örnek görüntüler

Dermatologlar melanomun erken evrelerinde, bu kanseri diğer iyi huylu benlerden ayırt etmede zorlanmaktadır. Uzmanlar melanom tespiti için genellikle dermoskopik görüntülerden ve biyopsiden faydalanmaktadır. Biyopsi, şüpheli bir lezyondan doku örneği alarak mikroskopik inceleme yapılmasını sağlayan bir işlemdir. Bu işlem uzman hekimler için zorlu ve zaman alıcı bir süreçtir. Ayrıca biyopsi, yüksek sağlık maliyeti ve hasta cildinde kalıcı yara izi oluşumu riski nedeniyle sıkça tercih edilmemektedir. Bunun yerine, cilt kanseri teşhisinde dermoskopik muayeneler yaygın olarak kullanılmaktadır. Dermoskopi, cilt lezyonlarının yapı, renk ve boyut gibi faktörlerin daha detaylı bir şekilde incelenmesini sağlayan bir dermoskop ile yapılmaktadır. Bu yöntem, dermatologların cilt lezyonlarını kapsamlı bir şekilde değerlendirmesine, erken tanı koymasına ve etkili tedavi planları geliştirmesine olanak tanımaktadır. Ancak, cilt lezyonlarını görsel olarak incelemek ve test etmek, biyopsi işleminde olduğu gibi dermatologlar için zaman alıcı bir süreç olup yüksek düzeyde uzmanlık

ve dikkat gerektirmektedir. Bu nedenle, cilt kanserinin erken tespiti, daha az müdahaleci ve daha etkili tedavi alternatiflerine ihtiyaç duymaktadır. Cilt kanserinin erken aşamalarda tespit ve tedavi edilmesi, genellikle başarılı sonuçlar elde etme oranını artırmaktadır. Bu durum, hastaların iyileşme sürecini hızlandırarak yaşam kalitelerini yükseltmektedir (Hameed ve ark., 2024; Hussain ve Toscano, 2024).

Son yıllarda bilgisayar destekli tanı (CAD) sistemleri, sağlık alanında ve özellikle cilt kanseri teşhis ve tedavisinde çok önemli ilerlemeler kaydetmiştir (Ozcan ve ark., 2024). Bu sistemler sayesinde uzman dermatologların cilt lezyonlarını hızlı ve doğru bir şekilde tespit etmeleri sağlanmaktadır. Görüntüden özellik çıkarma ve sınıflandırma CAD sistemlerinin temel işlemleri arasında bulunmaktadır (Toprak ve Aruk, 2024). CAD tabanlı algoritmaların performansı, heterojen ve düşük kaliteli tıbbi veriler ve dengesiz veri kümeleri nedeniyle olumsuz yönde etkilenmektedir. Makine öğrenmesinin bir alt dalı olan derin öğrenme ise CAD sistemlerine göre daha yüksek performanslar sağlamaktadır (Naeem ve Anees, 2024). Geleneksel yöntemlerdeki manuel özellik çıkarma yerine, derin öğrenme algoritmaları ham verilerden karmaşık görüntü özelliklerini hiyerarşik bir şekilde otomatik olarak öğrenmektedir. Bu modeller, büyük veri kümelerini işleme konusunda daha verimli olup, farklı hasta grupları ve görüntüleme teknikleri arasında güçlü bir genelleme yeteneği sunmaktadır. Ayrıca, sürekli öğrenme ve gelişen tıbbi uygulamalara adaptasyon, tanı doğruluğunu ve güvenilirliğini daha da iyileştirmektedir (Hermosilla ve ark., 2024).

Literatürde cilt kanseri sınıflandırması için Evrimsel Sinir Ağı (CNN) modelleri kullanılarak yapılmış birçok çalışma bulunmaktadır. Bunlardan, Rezaoana ve ark. tarafından sunulan çalışmada, VGG-16 ve VGG-19 CNN modelleri kullanılarak dokuz farklı cilt kanseri tipi sınıflandırılmıştır. Görüntü artırma ve transfer öğrenme yöntemleriyle modelin doğruluğu artırılmıştır. Geliştirilen yöntem ile %79.45 doğruluk, %76.00 F1-skoru, %78.00 duyarlılık sonuçları elde edilmiştir. (Rezaoana ve ark., 2020). Shete ve ark. çalışmalarında CNN kullanarak cilt kanserini teşhis etmek ve çeşitli sınıflara ayırmayı amaçlamıştır. Dermoskopi görüntülerinde gürültü ve çözünürlük iyileştirilmiş, görüntü artırma yöntemleri kullanılarak veri sayısı artırılmıştır. Ayrıca transfer öğrenme yöntemi ile görüntü tanıma doğruluğu geliştirilmiştir. CNN modelinin ağırlıklı ortalama hassasiyeti %88.00, duyarlılık değeri %74.00, F1-skoru %77.00 ve ResNet modeli ile doğruluk %90.51 olarak elde edilmiştir (Shete ve ark., 2021).

Tanna ve Sharma yapmış oldukları çalışmalarında, melanom görüntü verilerini kullanarak cilt kanseri tespiti için iki yöntem önermektedir. Bu yöntemler üç katmanlı bir CNN ile basit destek vektör makinelerinin (SVM) sınıflandırıcı algoritması olarak kullanıldığı modellerdir. Geliştirilen birinci yöntem SVM sınıflandırıcısı ile %79.39 doğruluk ve 0.81 AUC elde edilmiştir. İkinci yöntem ise CNN modeli ile %84.39 doğruluk oranına ulaşmıştır (Tanna ve Sharma, 2021). Subramanian ve ark. çalışmalarında, klinik görüntülere dayalı olarak cilt kanserini tespit ve sınıflandırmak için CNN modeli kullanılmıştır. Simülasyon sonuçları, toplam on altı katmandan oluşan CNN modelin %83.04 doğruluk oranı sağladığını göstermektedir (Raja Subramanian ve ark., 2021). Yılmaz ve ark., ISIC 2017 veri setini kullanarak cilt kanseri sınıflandırması için mobil ve gömülü cihazlara uygun hafif mimariler üzerinde araştırma yapmışlardır. Toplamda üç farklı model ve her biri için üç farklı toplu iş boyutu kullanılarak dokuz model oluşturulmuştur. Sonuçlar, NASNetMobile modelinin on altı toplu iş boyutuyla en iyi performansı gösterdiğini ortaya koymuştur (Yılmaz ve ark., 2021).

Gajera ve ark., çalışmalarında sekiz güncel CNN modelinden çıkarılan derin özelliklerin etkinliğini araştırmıştır. Ayrıca, melanom tespitinde sınır yerleştirme ve normalizasyon tekniklerinin etkisini keşfetmektedirler. Deneysel sonuçlar, DenseNet-121 modelinin çok katmanlı algılayıcı ile birlikte kullanıldığında, ISIC 2017 veri setinde %81.16 doğruluk oranı ortaya koymuştur (Gajera ve ark., 2023). Al-masni ve ark., araştırmalarında bir entegre tanı çerçevesi önermiştir. Bu çerçeve, deri

lezyonlarının sınırlarını segmentasyon aşamasını ve çoklu deri lezyonlarının sınıflandırma aşamasını birleştirmektedir. Önerilen entegre derin öğrenme modeli, üç bağımsız veri seti kullanılarak değerlendirilmiştir. Sonuçlar, entegre tanı sisteminde segment edilen lezyonların, ISIC 2017 için üç sınıfta %81.57, %81.34 ve %73.44 doğruluk oranları sergilemiştir (Al-masni ve ark., 2020).

Kaur ve ark. geliştirdiği model, lezyonların otomatik segmentasyonu amacıyla atrous konvolüsyonları temel alan bir CNN yapısına sahiptir. Bu mimari, semantik segmentasyon için etkili olduğu bilinen genişletilmiş konvolüsyonlara dayanmaktadır. Model, yeni bir katman yapısı ile tasarlanmış olup, hiper parametreler ayarlanarak performansın artırılması hedeflenmiştir. ISIC 2017 veri setinde test edilen model, %81.80 ortalama Jaccard indeksi elde etmiştir (Kaur ve ark., 2022). Hayat ve ark., cilt kanseri sınıflandırmasına yönelik derin öğrenme tabanlı bir yöntem önermiştir. ISIC 2017 veri seti kullanılarak InceptionV3, EfficientNetB0, ResNet50, MobileNetV2 ve NASNetMobile modelleri ile sınıflandırma yapılmıştır. Tekli modellerde en yüksek doğruluk %69.30 ile MobileNetV2 modelinde elde edilmiştir. Beş modelin birleşiminden oluşan topluluk modeli ise %80.60 doğrulukla performans göstermiştir (Hayat, 2024). Ashraf ve ark., çalışmalarında, gelişmiş ön ve son işleme adımları içeren tamamen otomatik bir derin öğrenme tabanlı lezyon segmentasyon yöntemi sunmuştur. Yöntemde UNet, ResUNet ve ResUNet++ modelleri kullanılmıştır. Ön işleme aşamasında, gereksiz kıl yapılarının giderilmesi için morfolojik filtrelerle bir boyama algoritması birleştirilmiştir. Son işlem aşamasında ise doğruluğu artırmak amacıyla test zamanı genişletme ve koşullu rastgele alan yöntemleri uygulanmıştır. Yöntem ISIC 2016 ve ISIC 2017 veri setlerinde ortalama %85.96 ve %80.05 Jaccard indeksi elde etmiştir (Ashraf ve ark., 2022).

Cilt kanserinin teşhis ve sınıflandırma doğruluğunu artırmak, bu süreçleri dermatologlar ve hastalar için daha kolay hale getirmek amacıyla çeşitli derin öğrenme tabanlı yöntemler geliştirilmiştir. Bu çalışmanın amacı, güncel CNN modellerinin cilt kanseri sınıflandırmasındaki performanslarını incelemek ve karşılaştırmalı analizini sunmaktır. Araştırma, açık erişimli ISIC 2017 veri kümesi kullanarak yirmi bir farklı CNN modelinin eğitilmesi ve değerlendirilmesini kapsamaktadır. Çalışmanın literatüre başlıca katkıları şunlardır:

- Güncel CNN modellerinin cilt kanseri tespiti başarılarını ISIC 2017 dermatolojik veri kümesi kullanılarak karşılaştırılmaktadır.
- Veri ön işleme, veri artırma ve transfer öğrenme tekniklerinin hangi CNN modellerinin başarısı üzerinde etkili olduğuna dair analiz sunulmaktadır.
- Cilt kanseri sınıflandırmasında kullanılan farklı CNN yöntemlerinin avantajları ve sınırlamaları hakkında kapsamlı bir analiz sunulmaktadır, gelecekteki araştırmalara yeni bakış açıları kazandırılmaktadır.

Makalenin organizasyonu şu şekilde yapılandırılmıştır: Materyal ve yöntem bölümünde, derin öğrenme ve CNN modelleri, kullanılan veri seti, değerlendirme metrikleri ve yöntemler sunulmuştur. Bulgular ve tartışma bölümünde ise kapsamlı deneysel sonuçlar ele alınmıştır. Son bölüm olan sonuç kısmında ise genel bir değerlendirme yapılmış ve gelecekteki çalışmalar için önerilerde bulunulmuştur.

MATERYAL VE METOT

Bu bölümünde ilk olarak çalışmada CNN modellerini eğitmek ve test etmek için kullanılan veri seti sunulmaktadır. Ardından derin öğrenme, CNN yapıları ve CNN mimarilerinden bahsedilmektedir. Daha sonra, CNN modellerinin başarımlarını değerlendirmek için kullanılan performans metrikleri açıklanmaktadır. Son olarak, önerilen yaklaşımın detayları sunulmaktadır.

Veri Seti

Bu çalışmada, Uluslararası Cilt Görüntü İş birliği (International Skin Imaging Collaboration, ISIC) tarafından sağlanan ISIC 2017 (Codella ve ark., 2018) veri setinden faydalanılmıştır. Şekil 2’de örnek görüntülerin verildiği ISIC 2017 veri seti, cilt lezyonlarının sınıflandırılmasında CNN modellerinin karşılaştırmalı analizini yürütmek için kullanılmıştır. Açık erişimli olarak yayınlanan ISIC 2017 veri seti literatürde sıkça kullanılmaktadır. Derin öğrenme modellerini eğitmek için uygun büyüklükteki bu veri setini kullanmak, cilt kanseri sınıflandırma modellerinin doğruluğunu ve genellemesini artırmada önemli avantajlar sunmaktadır.

Çizelge 1’de ISIC 2017 veri setinde bulunan üç sınıfa ait görüntülerin dağılımını sunulmaktadır. Bu tablodan da görüleceği gibi, MEL sınıfı 374 görüntü ve Seboreik keratoz (SK) 254 görüntüye sahiptir. Ayrıca Nevus (NV) sınıfı 1.372 görüntü ile veri kümesinde en fazla görüntü örneğine sahiptir. Bu dengesizlik ile sınıf başına düşen örneklerin yetersiz bir şekilde temsil edilmesi, uygun sınıflandırmayı daha zor hale getirerek modellerinin sınıflandırma performansını olumsuz yönde etkileyebilmektedir.



Şekil 2. ISIC 2017 veri setinin sınıflarına ait örnek görüntüler

Çizelge 1. ISIC 2017 veri setinin sınıflara göre görüntü sayıları


Sınıflar	Görüntü Sayısı
Melanoma	374
Nevus	1.372
Seboreik keratoz	254
Toplam	2.000

Derin Öğrenme Mimarileri

Derin öğrenme algoritmaları, insan beynine benzer karmaşık bir mimari ile farklı verilerden öğrenme yeteneğine sahiptir. Derin öğrenme tabanlı yöntemler, tıbbi görüntü analizinde, özellikle tahmin, teşhis ve tespit gibi görevlerde yaygın olarak kullanılmaktadır. Geleneksel yöntemlerle kıyaslandığında, mevcut sinir ağları, özellikle cilt lezyonu sınıflandırmasında üstün performans göstermektedir (Adegun ve Viriri, 2020). Sınıflandırmanın ilk adımı, görüntünün elde edilmesi ve sınıf özelliklerinin belirlenmesini içermektedir. Derin öğrenme alanında yaygın olarak kullanılan CNN’ler, görüntü işleme ve bilgisayarla görme sorunlarını çözmek için geliştirilmiş modellerdir (Nancy ve ark., 2023).

Evrişimsel Sinir Ağları

CNN mimarileri genellikle evrişim katmanı ile ortaklama katmanları arasındaki değişimi içermektedir (Cong ve Zhou, 2023). CNN mimarisi Şekil 3'de görüldüğü gibi beş bölümden oluşmaktadır. Bunlar: giriş katmanı, konvolüsyon katmanı, ortaklama katmanı, tam bağlantılı katman ve çıkış katmanıdır. CNN mimarileri, sinir ağı mimarilerinin tasarımında önemli bir rol oynamaktadır. Bir ağ mimarisi, katmanlar arasındaki uyum etkisini artırmalı ve ağdaki gereksiz hesaplamaları azaltmalıdır. Bu da modelin genellikle daha üstün performans sergilemesini sağlamaktadır (Cong ve Zhou, 2023).



Şekil 3. Temel CNN mimarisi (Nancy ve ark., 2023)

Evrişim katmanı, derin öğrenme mimarilerinin temel bileşenlerinden biridir ve özellikle görüntü işleme görevlerinde kritik bir rol oynamaktadır. Bu katman, giriş verisindeki yerel özellikleri tespit etmek için filtreler kullanarak görüntüyü analiz etmektedir. Her bir filtre, kenar, doku, desen gibi belirli bir özellik setini öğrenerek, giriş görüntüsündeki önemli bilgileri çıkarmaya yardımcı olmaktadır. Evrişim işlemi sonucunda elde edilen özellik haritaları, modelin daha derin katmanlarında daha karmaşık temsillerin oluşturulmasına olanak tanımaktadır. Ayrıca, evrişim katmanları, parametre paylaşımı sayesinde hesaplama verimliliğini artırmakta ve daha az bellek kullanarak derin ağların eğitimini kolaylaştırmaktadır. Bu özellikleri sayesinde, evrişim katmanları, cilt kanseri gibi karmaşık görüntü sınıflandırma görevlerinde etkili sonuçlar elde edilmesini sağlamaktadır (Dhillon ve Verma, 2020).

Her bir evrişimsel katmandan sonra, ortaklama katmanları verilerin boyutunu azaltarak en önemli bilgilerin seçilmesi sağlamaktadır. Bu azaltma, hesaplama yükünü en aza indirmek ve modelin temel özelliklere odaklanmasını artırmak için önemlidir (Musthafa ve ark., 2024).

Tam bağlantı katmanı, genellikle ağın son kısımlarında yer alan ve tüm nöronların bir önceki katmandaki tüm nöronlarla bağlantılı olduğu bir katmandır. Bu katman, evrişim katmanları tarafından çıkarılan özellikleri alarak, bu özelliklerin sınıflandırma veya regresyon gibi nihai çıktılara dönüştürülmesinde önemli bir rol oynamaktadır. Tam bağlantı katmanı, her nöronun, giriş verisindeki tüm özelliklerle etkileşime girmesini sağlayarak, modelin daha karmaşık ilişkileri öğrenmesine yardımcı olmaktadır. Bu katman, genellikle aktivasyon fonksiyonları ile birlikte kullanılmakta ve bu sayede modelin öğrenme kapasitesi artırılmaktadır. Cilt kanseri gibi tıbbi görüntüleme uygulamalarında, tam bağlantı katmanı, evrişim katmanlarından elde edilen özellikleri kullanarak, melanom veya diğer cilt lezyonlarının sınıflandırılmasında son karar mekanizmasını oluşturur. Bu nedenle, tam bağlantı katmanları, derin öğrenme modellerinin genel performansını artırmada kritik bir öneme sahiptir (Musthafa ve ark., 2024).

CNN Modelleri

Aşağıda belirtilen derin öğrenme modelleri, görüntü tanıma ve nesne tespiti alanlarında önemli katkılarda bulunmuş, çeşitli yenilikler ve teknikler içeren CNN modelleridir. Her bir modelin temel özellikleri ve yenilikçi yaklaşımları kısaca özetlenmiştir. Ayrıca CNN modellerinin katman ve parametre sayıları Çizelge 2’de verilmektedir.

EfficientNet, model boyutlandırma ve verimlilik üzerine odaklanan bir mimaridir. EfficientNet-b0, temel yapı taşları olarak derinlik, genişlik ve çözünürlük ölçeklendirmeyi birleştirmektedir. Bu model, daha az parametre ile yüksek doğruluk elde etmeyi amaçlamaktadır. b1'den b8'e kadar her bir versiyon, daha fazla parametre ve katman sayısı ile artan performans sunmaktadır (Tan ve Le, 2019). Inception mimarisi, çoklu filtre boyutlarını aynı katmanda kullanarak, farklı ölçeklerdeki özellikleri öğrenme yeteneği sunmaktadır. Inceptionv3, bu mimarinin en çok bilinen versiyonlarından biridir. Inceptionv4 ve InceptionResNetv2, daha da derinleşmiş yapılar ve yoğun bağlantılar ile performansı artırmayı hedefleyen mimarileridir (Szegedy ve ark., 2016). Xception, derin ayrıştırılabilir konvolüsyonlar kullanarak, özellik çıkarımını optimize eden bir mimaridir. Bu yaklaşım, modelin hesaplama verimliliğini artırırken, daha az parametre ile daha yüksek performans elde etmeyi mümkün kılmaktadır. Xception, özellikle büyük veri setlerinde derin öğrenme uygulamaları için etkili bir çözüm sunmaktadır (Chollet, 2016).

Çizelge 2. CNN modellerinin katman sayıları ile parametre sayıları

CNN Modelleri	Katman Sayısı	Parametre Sayısı (Milyon)
EfficientNet-b0	82	5.3
EfficientNet-b1	88	7.8
EfficientNet-b2	93	9.2
EfficientNet-b3	100	12
EfficientNet-b4	108	19
EfficientNet-b5	118	30
EfficientNet-b6	132	43
EfficientNet-b7	138	66
EfficientNet-b8	146	90
Inception-v3	159	24
Inception-v4	155	48
InceptionResNet-v2	164	56
Xception	126	23
VGG-13	13	133
VGG-16	16	138
VGG-19	19	143
DarkNet53	53	41
CSPDarkNet53	53	36
DenseNet121	121	8
DenseNet169	169	14
DenseNet201	201	20

VGG modeli, derin öğrenmede basit ama etkili bir yapı sunmaktadır. VGG13, VGG16 ve VGG19 versiyonları derinlik artışı ile model performansını artırmaktadır. Bu modeller, küçük filtre boyutları kullanarak derinlik kazandırmakta ve katmanlar arası yoğun bağlantılar ile özellik öğrenimini geliştirmektedir (Simonyan ve Zisserman, 2014). DarkNet, özellikle YOLO nesne tespiti algoritması için geliştirilmiş bir mimaridir. DarkNet53, derin öğrenme uygulamalarında yüksek hız ve doğruluk sağlamaktadır. CSPDarkNet53, bu yapının daha verimli bir versiyonudur ve özelliklerin daha iyi öğrenilmesi için parçalı yapılar kullanmaktadır (Redmon ve Farhadi, 2018). DenseNet, her katmanın önceki katmanlardan gelen tüm özellik haritalarını kullanmasına olanak tanıyan yoğun bağlantılar içeren bir mimaridir. DenseNet121, DenseNet169 ve DenseNet201 mimarileri, daha az parametre ile daha fazla bilgi akışı sağlamayı hedeflemektedir (Huang ve ark., 2016).

Performans Metrikleri

Modellerin sınıflandırma performansını ve etkinliklerini doğru bir şekilde değerlendirmek için bazı metrikler gerekmektedir. Bu çalışmada, cilt kanseri sınıflandırması için karşılaştırdığımız modeller yaygın olarak kullanılan metrikler kullanılarak değerlendirilmiştir. Modellerinin performans değerlendirmesinde başlıca kullanılan metrikler arasında doğruluk, kesinlik, duyarlılık, F1-skoru yer almaktadır. Gerçek Negatif (TN) değeri, doğru şekilde tespit edilen sınıf dışı görüntülerinin toplam sayısını, Gerçek Pozitif (TP) ise doğru tespit edilen sınıfa ait görüntülerinin toplam sayısını ifade eder. Yanlış Negatif (FN), yanlış şekilde sınıf dışı olarak belirlenen görüntü sayısını ve Yanlış Pozitif (FP) ise yanlış şekilde sınıf içi olarak tespit edilen sınıf dışı görüntüleri belirlemektedir.

Doğruluk, Denklem 1'de gösterildiği gibi, gerçek tahminlerin toplam sayısının tahmin edilen görüntülerin toplam sayısına oranıdır.

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

Denklem 2'de gösterilen kesinlik, doğru tespit edilen pozitif vakaların, gerçek pozitifler ile yanlış pozitiflerin toplamına oranıdır.

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

Duyarlılık, Denklem 3'de görüldüğü gibi, gerçek pozitiflerin sayısının, pozitif olarak sınıflandırılması beklenen tüm örnek sayılarının toplamına bölerek hesaplanmaktadır.

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

Denklem 4'de görülen F1-skor, kesinlik ve duyarlılığın harmonik ortalamasına eşittir. Dengesiz veri setlerinde daha iyi bir performans ölçütü sağlamaktadır.

$$F1 - \text{skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

BULGULAR VE TARTIŞMA

Bu bölümde, cilt kanseri teşhisinde kullanılan derin öğrenme tabanlı CNN modellerinin performans sonuçları sunulmakta ve bu sonuçların klinik uygulamalar üzerindeki etkileri tartışılmaktadır. ISIC 2017 veri seti üzerinde gerçekleştirilen deneyler, farklı CNN mimarilerinin doğruluk, kesinlik, duyarlılık ve F1-skoru gibi temel metrikler açısından nasıl bir performans sergilediğini ortaya koymaktadır.

Deney Ortamı

Çalışmamız için yapılan tüm değerlendirmeler, Intel Core i5 13600K işlemciye sahip, 32 GB DDR5 RAM kapasiteli ve grafik kartı olarak NVIDIA RTX 3090 GPU içeren Ubuntu 22.04 işletim sistemine sahip bir bilgisayarda gerçekleştirilmiştir. Deneyler, NVIDIA CUDA desteğine sahip PyTorch altyapısı ile birlikte yürütülmüştür. Eğitim ve test verisi için tutarlı ve adil sonuçlar elde etmek için tüm modeller aynı parametreler kullanılarak değerlendirilmiştir.

Veri Ön İşleme ve Veri Artırma

Görüntü ön işleme süreci, derin öğrenme modellerinin oluşturulmasında oldukça zorlu bir aşama olarak kabul edilmektedir. Bu aşamada, istenmeyen gürültülerin ortadan kaldırılması, düşük kaliteli veya güvenilir olmayan piksel verilerinin çıkarılması ve görüntülerin belirli kriterlere göre ölçeklendirilmesi sağlanmaktadır. Temel ön işleme unsurları arasında veri artırma ve yeniden ölçeklendirme işlemleri yer almaktadır. Ayrıca otomatik, esnek ve hassas bir veri işleme yöntemi

sunmaktadır. Çalışmamızda ISIC 2017 veri setinde bulunan farklı çözünürlükteki tüm görüntüler, $224 \times 224 \times 3$ boyutlarına dönüştürülmüştür.

Derin öğrenme modellerinin başarısı, çoğu zaman veri setinin büyüklüğü ve çeşitliliğine bağlıdır. Bu unsurlar modellerin aşırı öğrenmesini önlemede kritik bir rol oynamaktadır. Tıbbi alanlarda ve özellikle cilt kanseri sınıflandırması alanında, yeterli etiketlenmiş veri toplamak zorlu bir süreçtir. Bu sorunu aşmak için çeşitli veri artırma teknikleri kullanılmaktadır. Bu sayede, veri setini yapay olarak genişleterek, modellerin daha sağlam ve genelleştirilebilir özellikler öğrenmesine olanak tanımaktadır. Cilt kanseri lezyonlarını simüle etmek için görüntülerin döndürülmesi, yeniden boyutlandırılması ve renklerinin değiştirilmesi gibi işlemler yapılabilir. Böylece, model daha çeşitli örüntüler öğrenerek daha doğru sınıflandırma gerçekleştirebilir.

Veri artırma, modelin performansını artırmak amacıyla elde edilen verilerin çeşitliliğini artırmaya yönelik tekniklerdir. Döndürme, kırpma, ölçeklendirme, yansıtma ve gürültü ekleme gibi yöntemler, cilt lezyonlarının sınıflandırma performansını arttırmaktadır. Veri artırma işlemi, ön işleme sonrası çevrimiçi veya çevrimdışı gerçekleştirilebilmektedir. Bu çalışmada, veri setine çevrimiçi veri artırma yöntemi uygulanmıştır. Eğitim sürecinde, tüm görüntülere aynı işlemin uygulanması, modellerin adil bir değerlendirmesini sağlamak açısından önemlidir.

Kullanılan açık erişimli veri seti, rastgele üç farklı alt kümeye ayrılmıştır. Eğitim seti, tüm veri setinin %70'lik kısmını içermekte ve model parametrelerini ayarlamak için kullanılmaktadır. %15'lik oran, model için en uygun hiperparametreleri seçmek ve genelleme ile aşırı öğrenmeyi kontrol etmek amacıyla doğrulama seti olarak ayrılmıştır. Geri kalan %15'lik kısım ise test seti olarak kullanılmakta ve daha önce görülmemiş verilerle modelin objektif bir değerlendirmesi gerçekleştirilmektedir. Çizelge 3'de veri setinin eğitim, doğrulama ve test verisi olarak ayrıldıktan sonra sınıf başına düşen görüntü sayıları verilmektedir.

Çizelge 3. ISIC 2017 veri setinin eğitim, doğrulama, test ve toplam dağılımı

Veri seti bölümleri	MEL	NV	SK	Toplam
Eğitim verisi (%70)	262	960	178	1.400
Doğrulama verisi (%15)	56	206	38	300
Test verisi (%15)	56	206	38	300
Toplam (%100)	374	1.372	254	2.000

Deneysel Sonuçlar ve Tartışma

Bu bölümde, ISIC 2017 veri seti üzerinde EfficientNet (b0 – b8), Inception (v3-v4), InceptionResNet-v2, Xception, VGG (13-16-19), DarkNet53, CSPDarkNet53 ve DenseNet(121-169-201) olmak üzere toplam yirmi bir adet CNN modelinin performans sonuçları ve değerlendirmeleri sunulmaktadır. Çizelge 4'de bu CNN mimarilerinin doğruluk, kesinlik, duyarlılık ve F1-skora göre performanslarını karşılaştırmaktadır. Her bir modelin dört temel metrik açısından nasıl bir performans sergilediği incelendiğinde, özellikle öne çıkan ve düşük performans gösteren modeller belirginleşmektedir. Ayrıca karışıklık matrisi, sınıflandırma modelinin performansını değerlendirmek için kullanılan bir araçtır. Modelin tahminlerinin gerçek değerlerle karşılaştırılmasını sağlamaktadır. Performans metriklerine ek olarak bu bölümde seçilen bazı modellerin karmaşıklık matrisi analizlerine yer verilmiştir.


Çizelge 4'deki veriler incelendiğinde, doğruluk ve diğer metrikler açısından en iyi performans gösteren modeller, EfficientNet-b0 ve EfficientNet-b5 olmuştur. EfficientNet-b0 modeli %84.00 doğrulukla en yüksek değere sahiptir ve F1-skorda %78.59, kesinlikte %83.63 ve duyarlılıkta %74.96 ile dengeli bir performans sunmaktadır. EfficientNet-b5 ise %83.33 doğruluk ile en yüksek performans

açısından ikinci sırada yer almakta olup, duyarlılıkta en yüksek değerlerden biri olan %78.52'yi elde ederek güçlü bir performans sergilemiştir. Ayrıca F1-skorda %78.46 ve kesinlikte %78.42 ile diğer metriklerde de iyi bir denge yakalamıştır. Bu iki model, özellikle doğruluk ve F1-skor bakımından diğer modellere nazaran dikkat çekmektedir.

Çizelge 4. ISIC 2017 veri seti üzerinde CNN modellerinin performans sonuçları

CNN Modelleri	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)
EfficientNet-b0	84.00	83.63	74.96	78.59
EfficientNet-b1	82.00	78.59	73.53	75.49
EfficientNet-b2	82.33	78.85	72.70	75.19
EfficientNet-b3	82.00	79.25	71.95	74.52
EfficientNet-b4	82.67	79.75	71.99	74.83
EfficientNet-b5	83.33	78.42	78.52	78.46
EfficientNet-b6	81.00	75.76	72.48	73.15
EfficientNet-b7	81.33	77.96	70.91	72.94
EfficientNet-b8	82.67	81.31	69.59	74.05
Inception-v3	80.67	74.10	72.63	73.23
Inception-v4	79.33	76.14	66.36	69.96
InceptionResNet-v2	79.00	71.78	67.20	68.64
Xception	82.33	77.41	74.73	75.99
VGG-13	79.33	73.46	70.68	71.93
VGG-16	81.67	76.54	74.24	74.96
VGG-19	75.67	68.47	64.56	65.80
DarkNet53	83.33	77.58	76.20	76.41
CSPDarkNet53	82.33	79.39	73.72	76.19
DenseNet121	80.33	75.34	71.29	72.34
DenseNet169	80.33	75.65	69.71	71.37
DenseNet201	81.67	76.56	72.96	74.44

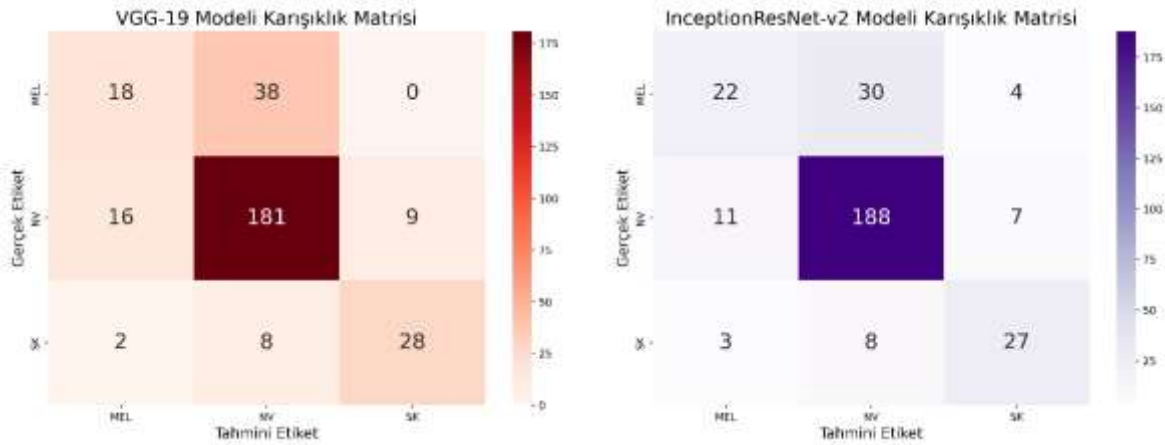
Şekil 4'de görülen EfficientNet-b0 modelinin karışıklık matrisi incelendiğinde, bu modelin toplam 300 görüntüden oluşan test setinde TP değeri MEL sınıfında 31 olarak belirlenirken, FP değeri 25 olarak kaydedilmiştir. NV sınıfında 192 TP ile etkileyici bir performans sergileyen model, yalnızca 14 görüntüyü yanlış sınıflandırmıştır. SK sınıfında ise 29 TP değeri elde edilmiş, 9 görüntü FP olarak tanımlanmıştır. Bu bulgular, EfficientNet-b0 modelinin NV sınıfını oldukça iyi tanımladığını göstermektedir. Ayrıca Şekil 4'de verilen EfficientNet-b5 modelinin sonuçları göre, MEL sınıfında 35 TP ile 21 görüntü FP olarak sınıflandırılmıştır. NV sınıfında 183 TP kaydedilmiş ve 23 görüntü yanlış sınıflandırılmıştır. SK sınıfında 32 TP değeri ile 6 FP durumu yaşanmıştır. Bu sonuçlar, EfficientNet-b5'in genel olarak güçlü bir performansa sahip olduğunu göstermektedir.



Şekil 4. EfficientNet-b0 ve EfficientNet-b5 CNN modellerinin karışıklık matrisi

Genel metriklere göre ISIC 2017 veri seti üzerinde en kötü performans gösteren modeller, VGG-19 ve InceptionResNet-v2 olmuştur. VGG-19 modeli, %75.67 doğrulukla en düşük değeri almış olup, F1-skoru sadece %65.80 ile sınırlı kalmıştır. %68.47 kesinlik ve %64.56 duyarlılık metrikleri açısından da en düşük değerleri sunmaktadır. Benzer şekilde, InceptionResNet-v2 modeli %79.00 doğruluk ve %68.64 F1-skoru ile performansı diğer modellere kıyasla düşük kalmış ve kesinlikte %71.78, duyarlılıkta %67.20 gibi daha alt seviyelerde bir performans göstermiştir.

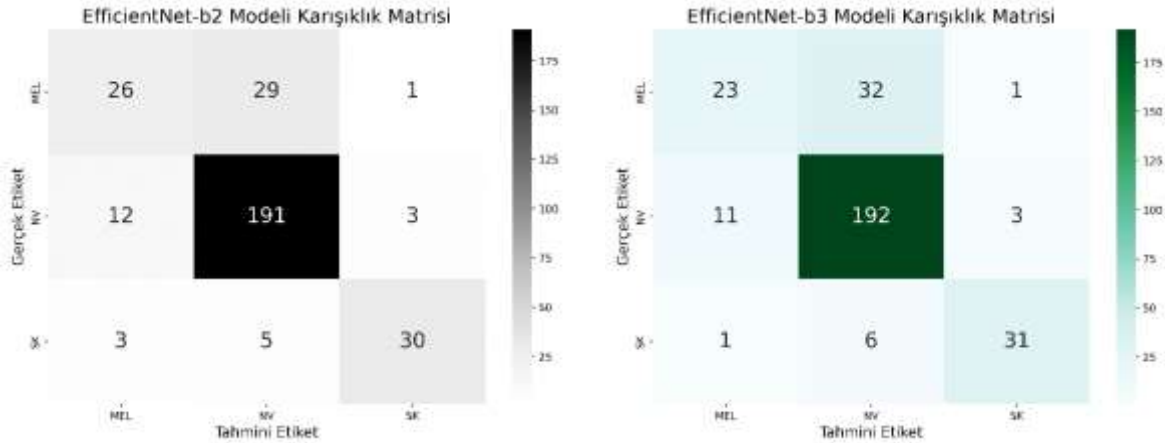
Şekil 5’de verilen VGG-19 modelinin karışıklık matrisine bakıldığında, MEL sınıfında 18 TP değeri kaydedilmiş ve 38 görüntü FP olarak atanmıştır. NV sınıfında ise 181 TN ile güçlü bir performans sergileyen model, 25 görüntüyü FP şekilde sınıflandırmıştır. SK sınıfında 28 TP değeri elde edilirken, 10 görüntü FP olarak tanımlanmıştır. Bu sonuçlar, VGG-19’un MEL sınıfında zayıf bir performans gösterdiğini, ancak genel olarak NV sınıfında oldukça iyi bir doğruluk sağladığını ortaya koymaktadır. InceptionResNet-v2 Şekil 5’deki karışıklık matrisinde ise, MEL sınıfında 22 TP değeri elde edilirken, 34 görüntü FP olarak sınıflandırılmıştır. NV sınıfında 188 TP kaydedilmiş ve yalnızca 18 görüntü FP durumuna düşmüştür. SK sınıfında 27 TP ile 11 FP durumu yaşanmıştır. Bu veriler, modelin NV sınıfında güçlü bir performans sergilediğini, ancak MEL sınıfında daha fazla iyileştirmeye ihtiyaç duyduğunu göstermektedir.



Şekil 5. VGG-19 ve InceptionResNet-v2 CNN modellerinin karışıklık matrisi

EfficientNet-b2 ve EfficientNet-b3 birbirine çok yakın performans sergileyen modeller arasında göze çarpmaktadır. EfficientNet-b2 modeli %82.33 doğruluk, %75.19 F1-skoru, %78.85 kesinlik ve %72.70 duyarlılık değerlerine sahipken, EfficientNet-b3 modeli %82.00 doğruluk, %74.52 F1-skoru, %79.25 kesinlik ve %71.95 duyarlılık sunmaktadır. Bu iki model, özellikle doğruluk ve kesinlik değerlerinde birbirine çok yakın performans sergileyerek benzer seviyede sonuçlar vermiştir.

EfficientNet-b2 modelinin Şekil 6’da görülen karışıklık matrisinde, MEL sınıfında 26 TP değeri ile 30 görüntü FP olarak sınıflandırılmıştır. NV sınıfında 191 TP kaydedilirken, yalnızca 15 görüntü FP olarak tanımlanmıştır. SK sınıfında ise 30 TP değeri elde edilmiş, ancak 8 görüntü FP olarak belirlenmiştir. Bu veriler, EfficientNet-b2’nin NV sınıfındaki yüksek doğruluğunu, ancak MEL sınıfında bazı zayıflıklar sergilediğini göstermektedir. Son olarak, Şekil 6’da verilen EfficientNet-b3 modelinin karışıklık matrisine bakıldığında, MEL sınıfında 23 TP ile 33 görüntü FP olarak tanımlanmıştır. NV sınıfında 192 TN kaydedilirken, yalnızca 14 görüntü FP durumu yaşanmıştır. SK sınıfında 31 TP değeri elde edilirken, 7 görüntü FP olarak belirlenmiştir. Bu sonuçlar, EfficientNet-b3 modelinin NV sınıfında sağlam bir performans sergilediğini, ancak MEL sınıfında daha fazla hata yaptığını ortaya koymaktadır.



Şekil 6. EfficientNet-b2 ve EfficientNet-b3 CNN modellerinin karışıklık matrisi

Genel olarak, Çizelge 4’de yer alan tüm modeller çeşitli metriklerde farklılıklar göstermektedir. Örneğin, EfficientNet-b0 doğruluk açısından en iyi sonucu elde ederken, EfficientNet-b5 duyarlılıkta öne çıkmıştır. EfficientNet-b8, kesinlik açısından %81.31 ile en yüksek değeri alırken, duyarlılıkta %69.59 gibi daha düşük bir performans sergileyerek belirli bir denge sağlayamamıştır. DarkNet53 modeli ise %83.33 doğruluk ve %76.41 F1-skoruyla yüksek bir performans göstermekte, duyarlılık ve kesinlik açısından da dengeli bir yapıya sahip olduğu görülmektedir.

SONUÇ

Bu çalışmada cilt kanseri teşhisinde kullanılan derin öğrenme tabanlı CNN modellerinin performansı kapsamlı bir şekilde değerlendirilmiştir. Elde edilen bulgular, EfficientNet-b0 modelinin %84.00 doğruluk oranıyla en yüksek başarıyı gösterdiğini ortaya koymaktadır. Bu sonuç, derin öğrenme tekniklerinin cilt kanseri sınıflandırmasında etkinliğini ve potansiyelini vurgulamaktadır. Ayrıca, diğer modellerin performansları arasında belirgin farklılıklar gözlemlenmiş, özellikle VGG-19 ve InceptionResNet-v2 modellerinin daha düşük başarı oranları dikkat çekmiştir. Bu durum, cilt kanseri teşhisinde kullanılan yöntemlerin sürekli olarak geliştirilmesi ve optimize edilmesi gerektiğini göstermektedir.

Gelecekteki araştırmalarda, bu alandaki gelişmeleri daha da ileriye taşımak için daha geniş ve çeşitli veri setlerinin kullanılması, model performansının artırılmasına katkı sağlayacaktır. Ayrıca, transfer öğrenme ve veri artırma tekniklerinin daha çeşitli varyasyonları ile bu modellerin doğruluğu artırılabilir. Ayrıca, derin öğrenme algoritmalarının, farklı cilt kanseri türlerini ayırt etme yeteneklerini daha iyi değerlendirmek için hibrid model yaklaşımları ve topluluk öğrenme yöntemleri üzerinde çalışmalar yapılabilir. Böylece, farklı mimarilerin güçlü yönlerinden faydalanarak daha yüksek başarı oranlarına ulaşılmasını sağlayabilir.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

KAYNAKLAR

- Adegun, A. A. ve Viriri, S. (2020) “FCN-Based DenseNet Framework for Automated Detection and Classification of Skin Lesions in Dermoscopy Images”, *IEEE Access*, 8, 150377-150396.

- Al-masni, M. A., Kim, D. H. ve Kim, T. S. (2020) "Multiple skin lesions diagnostics via integrated deep convolutional networks for segmentation and classification", *Computer Methods and Programs in Biomedicine*, 190.
- Ashraf, H., Waris, A., Ghafoor, M. F., Gilani, S. O. ve Niazi, I. K. (2022) "Melanoma segmentation using deep learning with test-time augmentations and conditional random fields", *Scientific Reports*, 12(1).
- Chollet, F. (2016) "Xception: Deep Learning with Depthwise Separable Convolutions".
- Codella, N. C. F., Gutman, D., Celebi, M. E., Helba, B., Marchetti, M. A., Dusza, S. W., Kallou, A., Liopyris, K., Mishra, N., Kittler, H. ve Halpern, A. (2018) "Skin lesion analysis toward melanoma detection: A challenge at the 2017 International symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC)", *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 168-172.
- Cong, S. ve Zhou, Y. (2023) "A review of convolutional neural network architectures and their optimizations", *Artificial Intelligence Review*, 56(3), 1905-1969.
- Dhillon, A. ve Verma, G. K. (2020) "Convolutional neural network: a review of models, methodologies and applications to object detection", *Progress in Artificial Intelligence*, 85-112.
- Dillshad, V., Khan, M. A., Nazir, M., Saidani, O., Alturki, N. ve Kadry, S. (2023) "D2LFS2Net: Multi-class skin lesion diagnosis using deep learning and variance-controlled Marine Predator optimisation: An application for precision medicine", *CAAI Transactions on Intelligence Technology*, 1-16.
- Gajera, H. K., Nayak, D. R. ve Zaveri, M. A. (2023) "A comprehensive analysis of dermoscopy images for melanoma detection via deep CNN features", *Biomedical Signal Processing and Control*, 79.
- Hameed, M., Zameer, A. ve Zahoor Raja, M. A. (2024) "A Comprehensive Systematic Review: Advancements in Skin Cancer Classification and Segmentation Using the ISIC Dataset", *CMES - Computer Modeling in Engineering and Sciences*, 2131-2164.
- Hayat, S. N. (2024) "Skin Cancer Detection Approach Using Convolutional Neural Network Artificial Intelligence", *IJIS: International Journal of Informatics and Information Systems*, 7(2), 46-54.
- Hermosilla, P., Soto, R., Vega, E., Suazo, C. ve Ponce, J. (2024) "Skin Cancer Detection and Classification Using Neural Network Algorithms: A Systematic Review", *Diagnostics*.
- Huang, G., Liu, Z., van der Maaten, L. ve Weinberger, K. Q. (2016) "Densely Connected Convolutional Networks".
- Hussain, S. I. ve Toscano, E. (2024) "An Extensive Investigation into the Use of Machine Learning Tools and Deep Neural Networks for the Recognition of Skin Cancer: Challenges, Future Directions, and a Comprehensive Review", *Symmetry*.
- Kaur, R., GholamHosseini, H., Sinha, R. ve Lindén, M. (2022) "Automatic lesion segmentation using atrous convolutional deep neural networks in dermoscopic skin cancer images", *BMC Medical Imaging*, 22(1).
- Musthafa, M. M., T R, M., V, V. K. ve Guluwadi, S. (2024) "Enhanced skin cancer diagnosis using optimized CNN architecture and checkpoints for automated dermatological lesion classification", *BMC Medical Imaging*, 24(1), 201.

- Naeem, A. ve Anees, T. (2024) "DVFNet: A deep feature fusion-based model for the multiclassification of skin cancer utilizing dermoscopy images", *PLoS ONE*, 19(3 March), 1-27.
- Nancy, V. A. O., Prabhavathy, P., Arya, M. S. ve Ahamed, B. S. (2023) "Comparative study and analysis on skin cancer detection using machine learning and deep learning algorithms", *Multimedia Tools and Applications*, 82(29), 45913-45957.
- Ozcan, T., Toprak, A. N., Aruk, I., Sahin, O. ve Ozcan, I. (2024) "Applications of deep learning techniques in healthcare systems: A review", *Journal of Clinical Practice & Research*, 45(5).
- Raja Subramanian, R., Achuth, D., Shiridi Kumar, P., kumar Reddy, K. N., Amara, S. ve Chowdary, A. S. (2021) "Skin cancer classification using Convolutional neural networks", *Proceedings of the Confluence 2021: 11th International Conference on Cloud Computing, Data Science and Engineering*, 13-19.
- Redmon, J. ve Farhadi, A. (2018) "YOLOv3: An Incremental Improvement".
- Rezaoana, N., Hossain, M. S. ve Andersson, K. (2020) "Detection and Classification of Skin Cancer by Using a Parallel CNN Model", *Proceedings of 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering, WIECON-ECE 2020*, 380-386.
- Shete, A. S., Sanjay Rane, A., Gaikwad, P. S. ve Patil, M. H. (2021) "DETECTION OF SKIN CANCER USING CNN ALGORITHM", *International Journal Of Advance Scientific Research And Engineering Trends*, 6(5), 2456-0774.
- Siegel, R. L., Giaquinto, A. N. ve Jemal, A. (2024) "Cancer statistics, 2024", *CA: A Cancer Journal for Clinicians*, 74(1), 12-49.
- Simonyan, K. ve Zisserman, A. (2014) "Very Deep Convolutional Networks for Large-Scale Image Recognition".
- Subramanian, B., Muthusamy, S., Thangaraj, K., Panchal, H., Kasirajan, E., Marimuthu, A. ve Ravi, A. (2024) "A Novel Approach Using Transfer Learning Architectural Models Based Deep Learning Techniques for Identification and Classification of Malignant Skin Cancer", *Wireless Personal Communications*, 134(4), 2183-2201.
- Szegedy, C., Vanhoucke, V., Ioffe, S. ve Shlens, J. (2016) *Rethinking the Inception Architecture for Computer Vision*.
- Tan, M. ve Le, Q. V. (2019) "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks".
- Tanna, R. ve Sharma, T. (2021) "Binary Classification of Melanoma Skin Cancer using SVM and CNN", *Proceedings - 2021 1st IEEE International Conference on Artificial Intelligence and Machine Vision, AIMV 2021*.
- Toprak, A. N. ve Aruk, I. (2024) "A Hybrid Convolutional Neural Network Model for the Classification of Multi-Class Skin Cancer", *International Journal of Imaging Systems and Technology*, 34(5), e23180.
- Wang, R., Chen, X., Wang, X., Wang, H., Qian, C., Yao, L. ve Zhang, K. (2024) "A novel approach for melanoma detection utilizing GAN synthesis and vision transformer", *Computers in Biology and Medicine*, 176, 108572.
- Yilmaz, A., Kalebasi, M., Samoylenko, Y., Guvenilir, M. E. ve Uvet, H. (2021) "Benchmarking of Lightweight Deep Learning Architectures for Skin Cancer Classification using ISIC 2017 Dataset".