

Dermskopik Görüntü Sınıflandırmada Temel Veri Artırım Yöntemlerinin Değerlendirilmesi

Aytuğ Onan^{1,3*}, Vahide Bulut^{2,3} ve Ahmet Ezgi³

¹Bilgisayar Mühendisliği Bölümü / Mühendislik ve Mimarlık Fakültesi, İzmir Kâtip Çelebi Üniversitesi, Türkiye

²Mühendislik Bilimleri Bölümü / Mühendislik ve Mimarlık Fakültesi, İzmir Kâtip Çelebi Üniversitesi, Türkiye

³Yazılım Mühendisliği Anabilim Dalı / Fen Bilimleri Enstitüsü, İzmir Kâtip Çelebi Üniversitesi, Türkiye

*(aytug.onan@ikcu.edu.tr)

Özet – Dermskopik görüntü sınıflandırması, cilt lezyonlarının tespiti ve teşhisi için hayati önem taşıyan bir süreçtir. Ancak, sınırlı veri ve sınıf dengesizliği gibi faktörler, derin öğrenme modellerinin performansını olumsuz etkileyebilmektedir. Bu zorlukların üstesinden gelmek ve sınıflandırma doğruluğunu artırmak amacıyla veri artırımı giderek daha fazla önem kazanmaktadır. Veri artırımı, mevcut veri kümesini çeşitlendirerek modelin daha genelleyici olmasını sağlayan bir tekniktir. Bu çalışmada, parlaklık, zıtlık, yansımalar, ton ve rastgele kesimler gibi geleneksel veri artırım yöntemleri incelenmiştir. Bu yöntemler, görüntülerdeki ışık, renk ve perspektif gibi özellikleri değiştirerek modelin farklı varyasyonlara karşı daha dayanıklı hale gelmesini amaçlar. Çalışma kapsamında, üç farklı derin öğrenme mimarisi (DenseNet-201, ResNet-152 ve InceptionV3) kullanılarak, veri artırım yöntemlerinin bir arada kullanıldıklarındaki etkinlikleri değerlendirilmiştir. Dermskopik görüntü sınıflandırmasının başarısı, hem doğru etiketlenmiş hem de geniş bir veri kümesine dayanır. Bu nedenle veri artırımı, modelin daha çeşitli ve gerçekçi örneklerle eğitilmesini sağlayarak sınıflandırma performansını artırabilir. Sonuç olarak, bu çalışma, dermskopik görüntü sınıflandırmasında veri artırımının önemini vurgulamakta ve farklı veri artırım yöntemlerinin derin öğrenme modelleriyle bir arada kullanılmasının potansiyelini incelemektedir. PH² veri kümesi üzerinde gerçekleştirilen deneysel analizler, farklı geleneksel veri artırım yöntemlerinin bir arada kullanılması ile elde edilen topluluk yaklaşımı tabanlı veri artırım yöntemlerinin, daha yüksek başarımla elde edilmesini sağladığını göstermektedir.

Anahtar Kelimeler – Dermskopik Görüntü Sınıflandırması, Veri Artırımı, Sınırlı Veri, Geleneksel Yöntemler, Derin Öğrenme Mimarileri

1. GİRİŞ

Cilt kanserleri, dünya genelinde yaygınlığı giderek artan ve önemli bir sağlık sorunu haline gelen hastalıklar arasında yer almaktadır [1]. Bu kanser türlerinin erken teşhis edilmesi, etkili tedavi seçeneklerinin uygulanması ve hastaların yaşam süresini artırma açısından kritik bir öneme sahiptir [2-3].

Dermskopik görüntüleme, cilt lezyonlarının mikroskop altında incelenmesi yöntemine dayalı olarak cilt kanserlerinin teşhisinde kullanılan güvenilir bir tekniktir [4]. Ancak, bu teknikte elde edilen görüntülerin analizi karmaşık ve uzmanlık gerektiren bir süreçtir [5]. Bu noktada, bilgisayar

destekli teşhis sistemleri (CDSS), doğru ve hızlı bir şekilde cilt lezyonlarını analiz etmekte önemli bir rol oynayabilir [6].

Hastalıkların erken teşhisi, tedavi sonuçlarını önemli ölçüde etkileyebilir. Özellikle cilt kanserleri gibi kanser türlerinde erken evrelerde teşhis edilen lezyonlar için daha başarılı sonuçlar elde edebilir [7]. Bilgisayar destekli teşhis sistemleri, bu erken teşhis hedefine ulaşmada büyük bir potansiyele sahiptir [6, 8].

Derin öğrenme, bu tür sistemlerin başarısını artırmak için son yıllarda önemli bir araç haline gelmiştir [9]. Derin öğrenme modelleri, büyük miktardaki verileri analiz etme ve karmaşık

desenleri öğrenme yetenekleri sayesinde cilt lezyonlarını otomatik olarak sınıflandırmak ve teşhis etmek için kullanılacak uygun yöntemler arasındadır [10]. Ancak, derin öğrenme modellerini kullanarak cilt kanserlerini doğru bir şekilde sınıflandırmak için yeterli ve çeşitli veriye ihtiyaç vardır [11, 12]. Bu noktada, veri artırımı yöntemleri devreye girmektedir.

Veri artırımı, mevcut veri kümesini çeşitlendirerek modelin daha genelleyici ve dayanıklı hale gelmesini sağlayan bir yöntemdir [13]. Veri artırımı, derin öğrenme modellerinin performansını artırmak için son derece önemli bir araç olarak öne çıkmaktadır. Özellikle sınırlı veriye sahip olduğumuz durumlarda, derin öğrenme modellerinin yeterli genelleme yapabilmesi zorlaşabilir [14]. Bu noktada, veri artırımı yöntemleri devreye girerek mevcut veri kümesini çeşitlendirir ve modele daha fazla örnek sunar. Bu durum, modelin farklı bakış açılarına ve varyasyonlara daha iyi uyum sağlamasına yardımcı olur [14, 15]. Ayrıca, veri artırımı sayesinde modelin aşırı uygunluk riski de azalmaktadır. Modelin eğitim verilerine aşırı derecede uyum sağlayarak yeni verilerde düşük performans gösterme riski, derin öğrenme modellerinde sıkça karşılaşılan bir durumdur [13]. Ancak, veri artırımıyla zenginleştirilen veri kümesi, modele daha çeşitli ve gerçekçi verilerle eğitilme imkânı sunar ve bu da aşırı uygunluk riskini azaltır [15]. Bu nedenle, veri artırımı derin öğrenme modellerinin güvenilir ve istikrarlı sonuçlar elde etmeleri için kritik bir rol oynamaktadır [13-15].

Çalışma kapsamında, üç farklı derin öğrenme mimarisi (DenseNet-201, ResNet-152 ve InceptionV3) kullanılarak, veri artırımı yöntemlerinin bir arada kullanıldıkları durumdaki etkinlikleri değerlendirilmiştir. Dermoskopik görüntü sınıflandırmasının başarısı, hem doğru etiketlenmiş hem de geniş bir veri kümesine dayanır. Bu nedenle veri artırımı, modelin daha çeşitli ve gerçekçi örneklerle eğitilmesini sağlayarak sınıflandırma performansını artırabilir. Sonuç olarak, bu çalışma, dermoskopik görüntü sınıflandırmasında veri artırımının önemini vurgulamakta ve farklı veri artırımı yöntemlerinin derin öğrenme modelleriyle bir arada kullanılmasının potansiyelini incelemektedir. PH² veri kümesi üzerinde gerçekleştirilen deneysel analizler, farklı geleneksel veri artırımı

yöntemlerinin bir arada kullanılması ile elde edilen topluluk yaklaşımı tabanlı veri artırımı yöntemlerinin, daha yüksek başarımla elde edilmesini sağladığını göstermektedir.

Çalışmanın devamı aşağıdaki yapıya sahiptir: İkinci bölümde, dermoskopik görüntü sınıflandırma alanında veri artırımı temelli yapılan çalışmalara odaklanılmaktadır. Üçüncü bölümde, metodoloji açıklanırken, dördüncü bölümde elde edilen deneysel sonuçlar ve bu sonuçların analizi sunulmaktadır. Beşinci ve son bölümde ise elde edilen sonuçlar değerlendirilerek sonuçlar ortaya konulmaktadır.

II. İLGİLİ ÇALIŞMALAR

Son yıllarda, cilt kanseri sınıflandırma ve segmentasyonu, araştırmacıların dikkatini çeken bir konu olmuş ve yapay zekâ (YZ) uygulamaları, cilt kanseri teşhisinin doğruluğunu artırmak için farklı çalışmalarda kullanılmıştır. Bu bölümde, cilt kanseri sınıflandırması alanında derin öğrenme modelleri ve veri artırımı yöntemleri kullanılarak gerçekleştirilen ilgili çalışmalara değinilmektedir. Hekler vd. [16] tarafından gerçekleştirilen çalışmada, yapay ve insan zekasının birleşimini kullanarak cilt kanseri analizine odaklanılmıştır. Görüntüler, Uluslararası Cilt Görüntüleme İşbirliği (ISIC) arşivlerinden ve HAM10000 veri kümesinden elde edilmiştir. Derin öğrenme yöntemleri, tek bir evrişimli sinir ağının (CNN) eğitimi için kullanılmıştır. Deney sonuçları, yapay ve insan zekasının birleşiminin diğer yöntemlere göre daha iyi sonuçlar elde ettiğini göstermiştir. Benzer biçimde, Albahar [17], cilt lezyonlarını sınıflandırmak için CNN kullanmıştır. CNN mimarisi, cilt lezyonlarını kötü veya iyi huylu lezyonlara ayırmak için kullanılmıştır. Sınıflandırma performansını değerlendirmek için doğruluk, eğri altında kalan alan (AUC), hassasiyet ve özgüllük gibi parametreler kullanılmıştır. Ancak, düzenleyici özellik azaltma veya seçimi için kullanılamamıştır. Bir başka çalışmada, Hosny vd. [18], transfer öğrenme ve derin öğrenme teknikleri kullanarak cilt kanseri türlerini ayırt etmiştir. Tasarım, PH² veri kümesini kullanarak test edilmiş ve eğitilmiştir. Hassasiyet, kesinlik, özgüllük ve doğruluk gibi yaygın nicel ölçütler, performans analizi için kullanılmıştır. Transfer öğrenme, yaygın nevüs, atipik nevüs ve melanom gibi çeşitli lezyonları sınıflandırmak için kullanılmıştır. Zhang

vd. [19], optimize edilmiş bir CNN kullanarak cilt kanseri tespitini araştırmıştır. Bir optimizasyon algoritması, ağırlıkların ve sapmaların seçimi için benimsenmiştir. DermIS ve Dermquest veri kümeleri, performansı değerlendirmek için kullanılmıştır. Sonuçlar, bu yöntemin diğer yöntemlere göre daha yüksek sonuçları elde ettiğini göstermiştir. Kadampur ve Al Riyae [20] derin öğrenme modeli kullanarak cilt kanserini tespit etmeyi amaçlayan bir çalışma yürütmüştür. Bu makalenin amacı, dermal hücre görüntülerini sınıflandırmak ve cilt kanserini tespit etmek için derin öğrenme tasarımı oluşturmaktır. Test ve model eğitimi için kullanılan temel veri kümesi HAM10000'dir. Pham vd. [21] tarafından geliştirilen çalışmada, ilk olarak, derin CNN ve Veri Artırımı kullanarak cilt lezyonlarının sınıflandırılmasının performansını artırmak için bir sınıflandırma modeli önerilmektedir. İkinci olarak, veri sınırlaması sorununu aşmak için görüntü veri artırmanın kullanımı incelenmekte ve farklı artırılmış örnek sayılarının çeşitli sınıflandırıcıların performansı üzerindeki etkisini değerlendirilmektedir.

III. METODOLOJİ

Bu bölümünde, çalışmanın temel yöntemlerini açıklamak üzere geleneksel veri artırım yöntemleri ve derin öğrenme mimarileri ele alınmaktadır.

A. Geleneksel Veri Artırım Yöntemleri

Bu çalışmada, parlaklık, zıtlık, yansımalar, ton ve rastgele kesimler gibi geleneksel veri artırım yöntemleri incelenmiştir [22]:

- **Parlaklık (*Brightness*) Artırımı:** Parlaklık artırımı, görüntülerin genel parlaklığını değiştirerek yapılır. Bu yöntemde, görüntüdeki piksellerin renk değerleri artırılarak veya azaltılarak parlaklık seviyesi değiştirilir. Bu, farklı aydınlatma koşullarında daha iyi genelleme yapılmasına yardımcı olabilir. Örneğin, cilt lezyonlarının farklı ışık koşullarında nasıl görünebileceği modelin öğrenmesine yardımcı olabilir. Parlaklık artırımında, görüntünün parlaklık seviyesini ayarlamak için bir katsayı kullanılır. Bu katsayı pozitif veya negatif olabilir. Pozitif bir katsayı görüntünün parlaklığını artırırken, negatif bir katsayı parlaklığı azaltır. Katsayının büyüklüğü, parlaklık değişikliğinin şiddetini belirler.
- **Zıtlık (*Contrast*) Artırımı:** Zıtlık artırımı, görüntüdeki renk aralığını genişletmek veya sıkıştırmak suretiyle zıtlığı artırır. Bu yöntemde, görüntünün parlak ve koyu bölgeleri arasındaki farklar artırılarak detayların daha belirgin hale gelmesi sağlanır. Modelin lezyonlar ile normal cilt dokusu arasındaki farkları daha iyi öğrenmesine yardımcı olabilir.
- **Yansımalar (*Flips*) Kullanımı:** Yansıma, görüntüyü yatay veya dikey olarak yansıtılarak elde edilir. Bu yöntemde, görüntünün sol-sağ veya yukarı-aşağı yönünde yansıtılması sağlanır. Bu, lezyonların farklı açılardan görünümünü modelin öğrenmesine yardımcı olabilir ve modelin yansımalara daha dayanıklı hale gelmesini sağlayabilir. Yansıma işlemi yatay (sol-sağ) veya dikey (yukarı-aşağı) yönünde olabilir. Her bir yansıma türü için bir karar vermek gerekmektedir. Bu işlem sırasında görüntünün boyutları değişmez.
- **Ton (*Hue*) Değişimi:** Ton artırımı, görüntüdeki renk tonunu değiştirerek yapılır. Renk tonu değişiklikleri, modelin farklı renk varyasyonlarını tanımasına yardımcı olabilir. Bu, cilt lezyonlarının farklı renk tonlarına sahip olabileceği durumları ele alır. Ton değişimi, görüntünün renk tonunu değiştiren bir katsayı kullanır. Bu katsayı, renk tekerleği üzerindeki açısız değişimi temsil eder. Değer genellikle -180 ila 180 derece arasında seçilir.
- **Rastgele Kesimler (*Random Crops*):** Rastgele kesimler, görüntüden rastgele bölgelerin kesilerek alındığı bir yöntemdir. Bu, modelin farklı bölge boyutlarını ve lezyonların farklı ölçeklerini öğrenmesine yardımcı olabilir. Aynı zamanda, görüntüdeki gereksiz arka planı çıkarmak suretiyle modele daha odaklı bir öğrenme sağlar. Rastgele kesimlerde, kesilen bölgelerin boyutları ve konuları belirlenmelidir. Bu parametreler, alınan kesitlerin farklı boyutlar ve bölgelerden gelmesini sağlar. Örneğin, bir görüntüyü 224x224 piksel boyutunda rastgele kesmek,

boyut parametresinin 224 olarak ayarlanmasını gerektirir.

B. Derin Öğrenme Mimarileri

Çalışma kapsamında, üç farklı derin öğrenme mimarisi (DenseNet-201, ResNet-152 ve InceptionV3) kullanılarak, veri artırım yöntemlerinin bir arada kullanıldıklarında durumdaki etkinlikleri değerlendirilmiştir.

DenseNet-201: DenseNet, yoğun bloklar olarak adlandırılan yapılar kullanarak derin ağ mimarisini geliştiren bir modeldir [23]. Bu yoğun bloklar, önceki katmanların çıkışlarını aynı yoğun bloğa giriş olarak ekler, böylece her katman öncekilerin çıktısına erişebilir. Bu mimari, ağırlık gradyanının daha iyi akmasını sağlamak ve öğrenme parametrelerini azaltmak için kullanılır.

ResNet-152: ResNet, derin ağlardaki kaybolan gradyan sorununu aşmak için rezidüel bağlantılar (residual connections) kullanarak ağ mimarisini genişleten bir modeldir [24]. Bu bağlantılar, katmanların çıktılarını doğrudan daha derin katmanlara aktararak gradyan kaybını engeller. ResNet-152, çok derin bir ağ yapısı kullanarak daha iyi öğrenme sağlamayı amaçlar.

Inception-V3: Inception mimarisi, farklı boyutlarda evrişimleri ve havuzlamaları bir araya getirerek ağırlık farklı ölçeklerdeki özellikleri yakalamasını sağlar. InceptionV3, derin öğrenme modelinin daha iyi temsil yeteneğine sahip olmasını amaçlar [25].

IV. DENEYSSEL SONUÇLAR

Deneysel analizlerde, PH² veri kümesi kullanılmıştır. PH² veri kümesi, dermoskopik görüntülerin hem segmentasyon hem de sınıflandırma algoritmaları üzerine karşılaştırmalı çalışmaları kolaylaştırmak amacıyla geliştirilmiş temel bir veri kümesidir [26]. Veri kümesi 200 görüntüden oluşmaktadır, dengesizlik oranı ise 4 tür. Deneysel analizler, üç farklı derin öğrenme mimarisi olan DenseNet-201, ResNet-152 ve InceptionV3 üzerinde gerçekleştirilmiştir. Her bir derin öğrenme mimarisi, veri artırım yöntemlerinin farklı kombinasyonları ile değerlendirilmiştir. Parlaklık, zıtlık, yansıma, ton değişiklikleri ve rastgele kesimler gibi geleneksel veri artırım yöntemlerinin tüm olası kombinasyonları, her bir derin öğrenme mimarisi için ayrı ayrı uygulanmıştır. Bu deneylerin amacı, veri artırım yöntemlerinin

farklı derin öğrenme mimarileri ile nasıl etkileşime girdiğini anlamak ve her bir kombinasyonun sınıflandırma performansına etkisini değerlendirmektir. Deneylerin karşılaştırılabilir ve anlamlı sonuçlar vermesi için derin öğrenme mimarileri için aynı parametre setleri kullanılmıştır. Her üç derin öğrenme mimarisi (DenseNet-201, ResNet-152 ve InceptionV3) için aynı optimizasyon algoritması (Adam), öğrenme oranı (0.001), toplam epok sayısı (50) ve batch boyutu (32) olarak seçilmiştir. Elde edilen sonuçlar, veri artırımının cilt lezyonu sınıflandırması için derin öğrenme yöntemlerinin performansını nasıl artırabileceğine dair önemli bilgiler sunmaktadır. Yöntemlerin değerlendirilmesinde, Matthews korelasyon katsayısı (MCC) ölçütü kullanılmaktadır. MCC, ikili sınıflandırma performansını değerlendirmek için kullanılan bir ölçüttür. Gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) değerlerini kullanarak hesaplanır. MCC, dengelemiş bir ölçüttür ve sınıf dengesizliği durumunda da etkilidir. MCC, aşağıdaki formülle hesaplanır:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}} \quad (1)$$

MCC değeri -1 ile +1 arasında değişir. +1 mükemmel bir sınıflandırma, 0 rastgele bir sınıflandırma ve -1 tersi bir sınıflandırma durumunu temsil eder. MCC, sınıflandırma performansını değerlendirmede hassasiyet ve özgüllük gibi diğer ölçütlerle kıyaslandığında daha bütüncül bir değer sunar, özellikle sınıf dengesizliği olduğunda daha güvenilir bir ölçüttür [27].

Deneysel analizlerde, temel veri artırım yöntemleri için farklı parametreler kullanılarak beş senaryo değerlendirilmiştir. Parlaklık artırımında, parlaklık değeri +0.1, +0.2, -0.1, -0.2 ve +0.3 olarak değiştirilmiştir. Zıtlık artırımında, zıtlık faktörü 1.5, 2.0, 0.7, 0.5 ve 0.3 olarak çeşitlendirilmiştir. Yansıma eklemede, yansıma açısı sırasıyla 10, 20, 30, 40 ve 50 derece olarak uygulanmıştır. Ton değişikliklerinde, +30, -30, +60, -60 ve +90 derece değerleri kullanılmıştır. Rastgele kesimlerde ise kesim boyutu 0.7, 0.6, 0.5, 0.4 ve 0.3 olarak belirlenmiştir.

Tablo 1’de temel veri artırım yöntemlerinin farklı parametreler ile değerlendirilmesi sonucu elde edilen sonuçlar sunulmaktadır. Tablo 1’de sunulan, farklı veri artırım yöntemleri ve parametre


değerlerinin derin öğrenme mimarilerinin performansına nasıl etki ettiğini göstermektedir. Parlaklık artırımı yöntemi incelendiğinde, özellikle Inception-V3 mimarisi için parlaklık değeri artırımının iyi sonuçlar verdiği görülmektedir. Zıtlık artırımı yönteminde ise zıtlık faktörünün 2 olduğu durumlar genel olarak en yüksek performansı sunmaktadır. Yansıma ekleme yöntemi, parametre değeri 30 derece olarak alındığında, diğer parametre değerlerine kıyasla daha yüksek başarımlar göstermektedir. Ton değişiklikleri ve rastgele kesimler yöntemlerinde ise daha karmaşık değişikliklerin ve kesim boyutlarının performansı artırdığı görülmektedir. Özellikle 90 derece ton artışı ve 0.6 kesim boyutunun, tüm mimariler için yüksek performanslı sonuçlar verdiği görülmektedir.

Tablo 1. Temel veri artırım yöntemlerinin farklı parametreler ile değerlendirilmesi sonucu elde edilen MCC değerleri

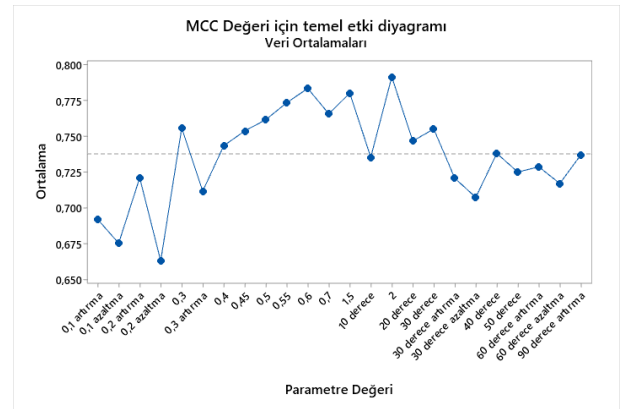
Veri Artırım Yöntemi	Parametre Değeri	DenseNet 201	ResNet-152	Inception-V3
Veri Artırımı Yok	-	0.562	0.564	0.570
Parlaklık Artırımı	0,1 artırma	0.586	0.687	0.803
Parlaklık Artırımı	0,2 artırma	0.622	0.724	0.817
Parlaklık Artırımı	0,3 artırma	0.605	0.702	0.828
Parlaklık Artırımı	0,1 azaltma	0.568	0.670	0.788
Parlaklık Artırımı	0,2 azaltma	0.540	0.654	0.795
Zıtlık Artırımı	1,5	0.754	0.776	0.810
Zıtlık Artırımı	2	0.762	0.790	0.822
Zıtlık Artırımı	0,7	0.731	0.763	0.803
Zıtlık Artırımı	0,5	0.718	0.750	0.811
Zıtlık Artırımı	0,3	0.702	0.740	0.825
Yansıma Ekleme	10 derece	0.698	0.713	0.795
Yansıma Ekleme	20 derece	0.716	0.715	0.809
Yansıma Ekleme	30 derece	0.721	0.732	0.812
Yansıma Ekleme	40 derece	0.705	0.710	0.799
Yansıma Ekleme	50 derece	0.689	0.698	0.788
Ton Değişiklikleri	30 derece artırma	0.671	0.680	0.811
Ton Değişiklikleri	30 derece azaltma	0.652	0.665	0.805
Ton Değişiklikleri	60 derece artırma	0.678	0.688	0.820
Ton Değişiklikleri	60 derece azaltma	0.662	0.676	0.813
Ton Değişiklikleri	90 derece artırma	0.691	0.695	0.825
Rastgele Kesimler	0,4	0.704	0.714	0.812
Rastgele Kesimler	0,45	0.712	0.725	0.824

Rastgele Kesimler	0,5	0.725	0.734	0.831
Rastgele Kesimler	0,55	0.732	0.748	0.840
Rastgele Kesimler	0,6	0.742	0.757	0.851


Şekil 1-3'te sırasıyla, geleneksel veri artırım yöntemleri ile elde edilen temel etki diyagramı, farklı parametre değerlerine ilişkin temel etki diyagramı ve derin öğrenme mimarilerine ilişkin temel etki diyagramı sunulmaktadır. Veri artırımı yöntemleri arasında en yüksek başarımın, zıtlık artırımı ile alındığı, bunun rastgele kesimler yöntemi tarafından takip edildiği görülmektedir.



Şekil 1. Veri artırım yöntemlerine ilişkin temel etki diyagramı



Şekil 2. Farklı parametre değerlerine ilişkin temel etki diyagramı



Şekil 3. Derin öğrenme mimarilerine ilişkin temel etki diyagramı

Parlaklık artırımı yönteminde, parlaklık değerini artırma ve azaltma senaryoları incelenmiştir. Bu yöntemin genelde tüm mimariler için performansı artırdığı görülmektedir. Özellikle Inception-V3 mimarisi parlaklık artırma yöntemine daha iyi cevap verirken, DenseNet-201 ve ResNet-152 de benzer şekilde artırılmış parlaklık değerlerinin performansı artırdığı gözlenmiştir. Zıtlık artırımı yönteminde, farklı zıtlık faktörleri değerlendirilmiştir. Bu yöntem de genelde tüm mimariler için performansı artırıcı etkiler göstermektedir. Yüksek zıtlık faktörleri (2 ve 1.5) genellikle daha iyi sonuçlar vermiştir. Yansıma ekleme yönteminin, özellikle Inception-V3 mimarisinin performansını artırdığı görülmektedir. Ton değişikliği yönteminde, renk tonu artırma ve azaltma senaryoları değerlendirilmiştir. Tüm mimariler için ton değişikliklerinin performansı artırdığı gözlenmiştir. Ton artırma ve azaltma senaryoları benzer şekilde performans göstermiştir. Rastgele kesimler yönteminde, farklı kesim boyutları incelenmiştir. Genelde kesim boyutu arttıkça performansın arttığı görülmektedir. Bu yöntem, özellikle Inception-V3 mimarisi için daha belirgin bir şekilde performansı artırıcı etki göstermiştir. Farklı veri artırım yöntemlerinin ve parametre değerlerinin, derin öğrenme mimarilerinin performansını artırmada etkili olduğu görülmüştür.

Temel veri artırım yöntemlerinin birlikte uygulanması ile elde edilen artırılmış veri kümelerinin, derin öğrenme mimarilerinin başarımını artırıp artırmadığını incelemek amacıyla, parlaklık artırımı (0,3 artırma), zıtlık artırımı (2), yansıma ekleme (30 derece), ton değişiklikleri (60 derece) ve rastgele kesimler (0,6) ile bunların tüm kombinasyonları değerlendirilmiştir. Tablo 2’de veri artırım yöntemlerinin birleştirilmesi ile elde

edilen konfigürasyonlara ilişkin MCC sonuçları sunulmaktadır.

Tablo 2’de sunulan sonuçlar incelendiğinde, veri artırımının yapılmadığı durumda, derin öğrenme modellerinin başarımlarının düşük kaldığı görülmektedir. Veri artırımının olmaması, modellerin çeşitli varyasyonları ve örüntüleri öğrenememesine neden olabilmektedir. Tablo 2’deki deneysel sonuçlar, çeşitli veri artırma yöntemlerinin farklı derin öğrenme modelleri (DenseNet201, ResNet-152, Inception-V3) üzerindeki etkisini değerlendirmektedir. Parlaklık artırımı ve zıtlık artırma tekniklerinin birleştirilmesi, tüm modellerde iyi sonuçlar elde edilmesine neden olmuştur, ancak Inception-V3 modeli en yüksek performansı göstermektedir. Parlaklık artırma ve yansıma ekleme teknikleri bir araya getirildiğinde, özellikle DenseNet201 modelinde daha düşük performans göstermiştir. Parlaklık artırma ve renk tonu değişikliklerinin birleştirilmesi sonucunda en iyi sonuçlar Inception-V3 modelinde görülmüştür.

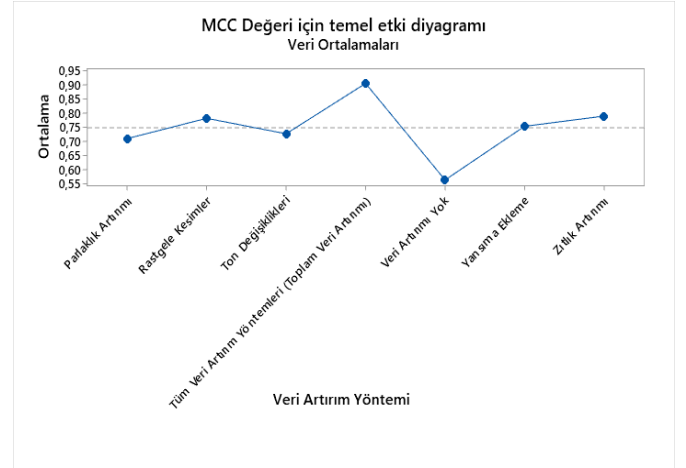
Tablo 2. Temel veri artırım yöntemlerinin birleştirilmesi ile elde edilen konfigürasyonların MCC değerleri

Veri Artırım Yöntemi	Dense Net201	ResNet-152	Inception-V3
Veri Artırımı Yok	0.562	0.564	0.570
Parlaklık Artırımı	0.605	0.702	0.828
Zıtlık Artırımı	0.762	0.790	0.822
Yansıma Ekleme	0.721	0.732	0.812
Ton Değişiklikleri	0.678	0.688	0.820
Rastgele Kesimler	0.742	0.757	0.851
Parlaklık Artırımı + Zıtlık Artırımı	0.798	0.812	0.836
Parlaklık Artırımı + Yansıma Ekleme	0.759	0.770	0.818
Parlaklık Artırımı + Ton Değişiklikleri	0.725	0.743	0.831
Parlaklık Artırımı + Rastgele Kesimler	0.812	0.823	0.857
Zıtlık Artırımı + Yansıma Ekleme	0.784	0.805	0.840
Zıtlık Artırımı + Ton Değişiklikleri	0.780	0.801	0.835
Zıtlık Artırımı + Rastgele Kesimler	0.843	0.858	0.876
Yansıma Ekleme + Ton Değişiklikleri	0.772	0.784	0.821
Yansıma Ekleme + Rastgele Kesimler	0.817	0.829	0.854
Ton Değişiklikleri + Rastgele Kesimler	0.803	0.815	0.844
Parlaklık Artırımı + Zıtlık Artırımı + Yansıma Ekleme	0.844	0.862	0.875
Parlaklık Artırımı + Zıtlık Artırımı + Ton Değişiklikleri	0.827	0.842	0.863
Parlaklık Artırımı + Zıtlık Artırımı + Rastgele Kesimler	0.870	0.881	0.893
Parlaklık Artırımı + Yansıma Ekleme + Ton Değişiklikleri	0.801	0.815	0.839
Parlaklık Artırımı + Yansıma Ekleme + Rastgele Kesimler	0.847	0.859	0.880

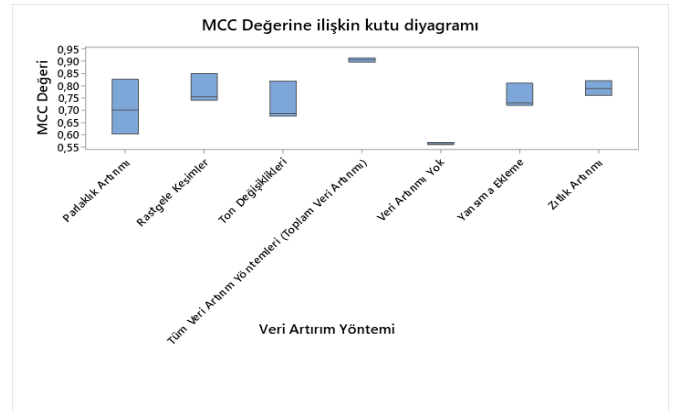
Zıtlık Artırımı + Yansıma Ekleme + Ton Değişiklikleri	0.827	0.839	0.860
Zıtlık Artırımı + Yansıma Ekleme + Rastgele Kesimler	0.872	0.887	0.897
Parlaklık Artırımı + Zıtlık Artırımı + Yansıma Ekleme + Ton Değişiklikleri	0.868	0.880	0.894
Parlaklık Artırımı + Zıtlık Artırımı + Yansıma Ekleme + Rastgele Kesimler	0.901	0.912	0.920
Tüm Veri Artırım Yöntemleri (Toplam Veri Artırımı)	0.897	0.908	0.915

Parlaklık artırma ve rastgele kesimlerin birleştirilmesi, tüm modellerde yüksek performans sağlamıştır, en yüksek performans ise Inception-V3 modeli tarafından elde edilmiştir. Diğer veri artırım yöntemleri birleştirmelerinde de genellikle başarımın, veri artırımı olmayan ya da veri artırımı yöntemlerinin tek başına kullanıldığı durumlara kıyasla daha yüksek sonuçlar verdiği görülmektedir. Tüm veri artırma yöntemleri birleştirildiğinde, genellikle Inception-V3 ve ResNet-152 modellerinin en yüksek performansı gösterdiği görülmüştür.

Şekil 4'te veri artırım yöntemlerinin karşılaştırılmasına yönelik temel etki diyagramı, Şekil 5'te ise veri artırım yöntemleri ile elde edilen MCC değerlerine ait kutu diyagramı sunulmaktadır. Deneysel sonuçlar, veri artırımı olmadığında, modellerin düşük MCC değerlerine sahip olduğunu göstermektedir. Bu, modelin veri eksikliği nedeniyle düşük performans gösterdiğine işaret etmektedir. Tüm veri artırma yöntemlerinin bir araya getirilmesi, modellerin genel performansını önemli ölçüde artırmıştır. Bu kombinasyon, yüksek MCC değerleri ile sonuçlanmıştır. Veri artırma yöntemleri model performansını artırma konusunda etkili olmuştur. Özellikle tüm yöntemlerin bir arada kullanılması, en yüksek MCC değerlerini elde etmek için etkili bir strateji olarak görünmektedir.



Şekil 4. Veri artırım yöntemlerinin karşılaştırılmasına yönelik temel etki diyagramı



Şekil 5. Veri artırım yöntemleri ile elde edilen MCC değerleri için kutu diyagramı

V. SONUÇ

Dermoskopik görüntü sınıflandırması, cilt lezyonlarının erken teşhisi ve tespiti için kritik bir adımdır. Ancak sınırlı veri ve sınıf dengesizliği gibi faktörler, derin öğrenme modellerinin performansını olumsuz etkileyebilir. Bu çalışma, bu zorlukların üstesinden gelmek ve sınıflandırma doğruluğunu artırmak amacıyla veri artırımının performansını incelemektedir. Veri artırımı, mevcut veri kümesini çeşitlendirerek modelin daha genelleme hale gelmesini sağlayan güçlü bir tekniktir. Parlaklık, zıtlık, yansımalar, ton değişiklikleri ve rastgele kesimler gibi geleneksel veri artırım yöntemleri, görüntülerin farklı özelliklerini değiştirerek modelin çeşitli varyasyonlara daha dirençli hale gelmesini amaçlar. Bu çalışmada, üç farklı derin öğrenme mimarisi (DenseNet-201, ResNet-152 ve InceptionV3) kullanılarak, bu veri artırım yöntemlerinin bir arada kullanıldıklarındaki etkinlikleri değerlendirilmiştir. Deneysel analizler, dermoskopik görüntü

sınıflandırmasının başarısının, hem doğru etiketlenmiş hem de geniş bir veri kümesine dayandığını ortaya koymaktadır. Bu nedenle veri artırımı, modelin daha çeşitli ve gerçekçi örneklerle eğitilmesini sağlayarak sınıflandırma performansını artırabilir. Elde edilen sonuçlar, geleneksel veri artırma yöntemlerinin bir arada kullanılmasının, özellikle topluluk yaklaşımı tabanlı yöntemlerin, daha yüksek performans sağladığını göstermektedir. Bu sonuçlar, derin öğrenme modellerinin sınıflandırma performansını artırmak için farklı veri artırma yöntemlerinin etkili bir şekilde birleştirilebileceğini göstermektedir. Bu çalışma, dermoskopik görüntü sınıflandırması için geleneksel veri artırma yöntemlerinin bir arada kullanılmasının potansiyelini değerlendirmektedir. İleriki çalışmalarda, gelişmiş veri artırma stratejilerinin ve derin öğrenme modellerinin kullanılmasıyla daha yüksek performans elde edilebilir. Derin öğrenme modellerinin hiperparametre ayarları ve mimarileri üzerindeki etkileri daha ayrıntılı bir şekilde incelenebilir. Sınıf dengesizliği gibi spesifik zorlukların üstesinden gelmek için daha özelleştirilmiş veri artırma yöntemleri geliştirilebilir. Farklı veri kümeleri ve görüntü modaliteleri üzerinde bu yaklaşımın genelleme yeteneği değerlendirilebilir.

TEŞEKKÜR

Bu çalışma, TÜBİTAK 122E601 numaralı proje kapsamında desteklenmiştir.

KAYNAKLAR

- [1] Diepgen, T. L., & Mahler, V. (2002). The epidemiology of skin cancer. *British Journal of Dermatology*, 146(s61), 1-6.
- [2] Melarkode, N., Srinivasan, K., Qaisar, S. M., & Plawiak, P. (2023). AI-Powered Diagnosis of Skin Cancer: A Contemporary Review, Open Challenges and Future Research Directions. *Cancers*, 15(4), 1183.
- [3] ul Huda, N., Amin, R., Gillani, S. I., Hussain, M., Ahmed, A., & Aldabbas, H. (2023). Skin Cancer Malignancy Classification and Segmentation Using Machine Learning Algorithms. *JOM*, 1-15.
- [4] Lama, N., Hagerty, J., Nambisan, A., Stanley, R. J., & Van Stoecker, W. (2023). Skin Lesion Segmentation in Dermoscopic Images with Noisy Data. *Journal of Digital Imaging*, 1-11.
- [5] Adegun, A., & Viriri, S. (2021). Deep learning techniques for skin lesion analysis and melanoma cancer detection: a survey of state-of-the-art. *Artificial Intelligence Review*, 54, 811-841.
- [6] Stiff, K. M., Franklin, M. J., Zhou, Y., Madabhushi, A., & Knackstedt, T. J. (2022). Artificial intelligence and melanoma: A comprehensive review of clinical, dermoscopic, and histologic applications. *Pigment Cell & Melanoma Research*, 35(2), 203-211.
- [7] Olayah, F., Senan, E. M., Ahmed, I. A., & Awaji, B. (2023). AI techniques of dermoscopy image analysis for the early detection of skin lesions based on combined CNN features. *Diagnostics*, 13(7), 1314.
- [8] Senan, E. M., & Jadhav, M. E. (2019). Classification of dermoscopy images for early detection of skin cancer—a review. *International Journal of Computer Applications*, 975, 8887.
- [9] Baig, R., Bibi, M., Hamid, A., Kausar, S., & Khalid, S. (2020). Deep learning approaches towards skin lesion segmentation and classification from dermoscopic images—a review. *Current Medical Imaging*, 16(5), 513-533.
- [10] Grignaffini, F., Barbuto, F., Piazzi, L., Troiano, M., Simeoni, P., Mangini, F., ... & Frezza, F. (2022). Machine Learning Approaches for Skin Cancer Classification from Dermoscopic Images: A Systematic Review. *Algorithms*, 15(11), 438.
- [11] Dong, S., Wang, P., & Abbas, K. (2021). A survey on deep learning and its applications. *Computer Science Review*, 40, 100379.
- [12] Mirikharaji, Z., Abhishek, K., Bissoto, A., Barata, C., Avila, S., Valle, E., ... & Hamarneh, G. (2023). A survey on deep learning for skin lesion segmentation. *Medical Image Analysis*, 102863.
- [13] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
- [14] Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J., & Shen, F. (2022). Image data augmentation for deep learning: A survey. *arXiv preprint arXiv:2204.08610*.
- [15] Khosla, C., & Saini, B. S. (2020, June). Enhancing performance of deep learning models with different data augmentation techniques: A survey. In *2020 International Conference on Intelligent Engineering and Management (ICIEM)* (pp. 79-85). IEEE.
- [16] Hekler, A., Utikal, J. S., Enk, A. H., Hauschild, A., Weichenthal, M., Maron, R. C., ... & Thiem, A. (2019). Superior skin cancer classification by the combination of human and artificial intelligence. *European Journal of Cancer*, 120, 114-121.
- [17] Albahar, M. A. (2019). Skin lesion classification using convolutional neural network with novel regularizer. *IEEE Access*, 7, 38306-38313.
- [18] Hosny, K. M., Kasseem, M. A., & Foad, M. M. (2018, December). Skin cancer classification using deep learning and transfer learning. In *2018 9th Cairo international biomedical engineering conference (CIBEC)* (pp. 90-93). IEEE.
- [19] Zhang, N., Cai, Y. X., Wang, Y. Y., Tian, Y. T., Wang, X. L., & Badami, B. (2020). Skin cancer diagnosis based on optimized convolutional neural network. *Artificial intelligence in medicine*, 102, 101756.
- [20] Kadampur, M. A., & Al Riyae, S. (2020). Skin cancer detection: Applying a deep learning based model driven

- architecture in the cloud for classifying dermal cell images. *Informatics in Medicine Unlocked*, 18, 100282.
- [21] Pham, T. C., Luong, C. M., Visani, M., & Hoang, V. D. (2018). Deep CNN and data augmentation for skin lesion classification. In *Intelligent Information and Database Systems: 10th Asian Conference, ACIIDS 2018, Dong Hoi City, Vietnam, March 19-21, 2018, Proceedings, Part II* 10 (pp. 573-582). Springer International Publishing.
- [22] Abdelhalim, I. S. A., Mohamed, M. F., & Mahdy, Y. B. (2021). Data augmentation for skin lesion using self-attention based progressive generative adversarial network. *Expert Systems with Applications*, 165, 113922.
- [23] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- [24] 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).
- [25] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- [26] Mendonça, T., Ferreira, P. M., Marques, J. S., Marcal, A. R., & Rozeira, J. (2013, July). PH 2-A dermoscopic image database for research and benchmarking. In *2013 35th annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 5437-5440). IEEE.
- [27] Pérez, E., & Ventura, S. (2023). Progressive growing of Generative Adversarial Networks for improving data augmentation and skin cancer diagnosis. *Artificial Intelligence in Medicine*, 141, 102556.