





Görüntü artırma tekniklerinin cilt kanseri türleri üzerinde evrimsel sinir ağları ile sınıflandırma başarılarının karşılaştırılması

Comparison of the classification performance of image augmentation techniques with convolutional neural networks on skin cancer types

Ömer Özcan^{1,*} , Muhammed Karaaltun² 

¹ Selçuk Üniversitesi, Bilgisayar Teknolojileri Bölümü, 42630, Konya, Türkiye

² KTO Karatay Üniversitesi, Bilgisayar Mühendisliği Bölümü, 42050, Konya, Türkiye

Öz

Derin öğrenme yaklaşımlarından evrimsel sinir ağları algoritması ile görüntü veri setleri üzerinde sınıflandırma çalışmaları yaygın olarak tıp ve tarım gibi birçok alanda başarılı bir şekilde yapılmaktadır. Ancak, görüntü veri setleri içerisinde bulunan sınıfların örnek sayıları dengesiz olduğu durumlarda bu algoritmanın sınıflandırma başarımı olumsuz yönde etkilenmektedir. Genelde çoğunluk sınıfının aksine azınlık sınıfı(ları) evrimsel sinir ağları algoritması tarafından iyi bir şekilde öğrenilmemektedir. Bunun gibi durumlarda aşırı örnekleme yöntemlerine başvurmak başarılı sonuçlar alınmasını sağlamaktadır. Aşırı örnekleme yöntemleri ile azınlık sınıfı(ları) örneklerinin sayısı artırılarak çoğunluk sınıfının örnek sayısına yakın ya da eşit olmaktadır. Bu çalışmada literatürde sıkça kullanılan; yer değiştirme, döndürme, rastgele silme, gürültü ekleme, resimlerin karıştırılması, çekirdek filtreleri, çekişmeli üretici ağlar, çevirme, özellik uzayı dönüşümü, kırma ve renk uzayı dönüşümü aşırı örnekleme yöntemleri Ham10000 veri seti üzerinde uygulanmıştır. Uygulama sonucunda elde edilen sonuçlara göre sınıflandırma başarısı açısından aşırı örnekleme yöntemleri karşılaştırılmıştır. Üç farklı evrimsel sinir ağları modellerinden; ResNet50, DenseNet201, MobileNet ile elde edilen sınıflandırma sonuçlarına göre doğruluk açısından ResNet50 modelinde gürültü ekleme yöntemi 0.967, DenseNet201 modelinde renk uzayı dönüşümü yöntemi 0.965 ve MobileNet modelinde ise Resimlerin karıştırılması yöntemi 0.974 sınıflandırma başarısı değeri ile diğer aşırı örnekleme yöntemlerinden daha iyi bir sonuç elde etmiştir.

Anahtar kelimeler: Aşırı örnekleme, Derin öğrenme, Evrimsel sinir ağı, Görüntü, Yetersiz örnekleme.

1 Giriş

Evrimsel Sinir Ağı (ESA), hiyerarşik özellik öğrenme yetenekleri sayesinde hastalıkların tahmin edilmesi, el yazısı tanıma, bilgisayar görmesi, görüntülerin sınıflandırılması alanlarında yaygın olarak kullanılmaktadır [1]–[4]. Son yıllarda ImageNet veri seti üzerinde evrimsel sinir ağı tabanlı yöntemler ile yapılan sınıflandırma çalışmaları başarılı sonuçlar vermiştir [5], [6]. Her ne kadar ImageNet

Abstract

Classification studies on image data sets with convolutional neural networks algorithm, which is one of the deep learning approaches, are widely performed successfully in many fields such as medicine and agriculture. However, in cases where the sample numbers of the classes in the image datasets are imbalanced, the classification performance of this algorithm is negatively affected. In general, unlike the majority class, the minority class(es) are not well learned by the convolutional neural network algorithm. In such cases, applying oversampling methods provides successful results. With oversampling methods, the number of minority class(s) samples is increased, making it close to or equal to the sample number of the majority class. In this study, translation, rotation, random erasing, noise injection, mixing of images, kernel filters, generative adversarial networks, flipping, feature space transformation, cropping and color space transformation oversampling methods frequently used in the literature were applied on the Ham10000 dataset. According to the results obtained as a result of the study, oversampling methods have been compared in terms of classification performance. From three different convolutional neural network models, according to the classification results obtained with ResNet50, DenseNet201, MobileNet, in terms of accuracy, the noise injection method in the ResNet50 model was 0.967, the color space transformation method in the DenseNet201 model was 0.965, and in the MobileNet model, the mixing of images method had a classification performance value of 0.974 which was better than the other oversampling methods.

Keywords: Convolutional neural network, Deep learning, Image, Oversampling, Undersampling.


gibi örnek sayısının çok fazla olduğu veri setlerinde evrimsel sinir ağları başarılı sonuçlar verse de örnek sayısının yetersiz olduğu dengesiz veri setlerinde sınıflandırma başarımının düştüğü gözlemlenmektedir [7]. Evrimsel sinir ağı gibi derin öğrenme tabanlı yaklaşımlarda örnek sayısının az olduğu durumlarda ya da örneklerin birbirine çok benzediği durumlarda aşırı öğrenme sorunu meydana gelmektedir [8]. Aşırı öğrenme durumu meydana

* Sorumlu yazar / Corresponding author, e-posta / e-mail: oozcan@selcuk.edu.tr (Ö. Özcan)

Geliş / Received: 24.03.2023 Kabul / Accepted: 24.08.2023 Yayımlanma / Published: 15.10.2023

doi: 10.28948/ngumuh.1270466

geldiğinde evrimsel sinir ağı yüksek eğitim oranlarına ulaşmakta, ancak ağı daha önce karşılaşmadığı verilerle test edildiğinde başarısız sonuçlar vermektedir [9], [10]. Şekil 1’de örnek bir aşırı öğrenme durumu verilmiş olup eğitim doğruluğu ve test verisi ile doğrulama oranlarına bakıldığında ağı yüksek oranlarda eğitilmiş olmasına rağmen az sayıda örnek ile eğitildiğinden dolayı doğrulama aşamasında düşük sonuçlar verdiği görülmektedir [11], [12].




Şekil 1. Aşırı öğrenme durumu

Dengesiz veri setlerindeki bir başka problem ise azınlık sınıfları ile çoğunluk sınıflarının örnek sayıları arasında çok fazla fark olabilmesidir. Örnek bir dengesiz veri setinde %95 oranında sağlıklı, %5 oranında hastalıklı örneklerin bulunduğu durumda hastalıklı örneklerin tamamının yanlış tahmin edildiği durumda bile doğruluk oranı %95 olarak hesaplanmaktadır.

Dengesiz veri setlerinin sebep olduğu sorunların çözümü için sunulan çözümler yetersiz örnekleme ve aşırı örnekleme olmak üzere iki ana başlık altında incelenmektedir.

Yetersiz örnekleme yönteminde dengesiz veri setlerindeki çoğunluk sınıflarının örnek sayıları azınlık sınıfları ile eşitlenerek indirgenmektedir.



Şekil 2. Örnek dengesiz veri seti

Yetersiz örnekleme yöntemi eğer azınlık sınıflarının örnek sayıları ağı eğitimi için yeterli ise dengesiz veri seti probleminde bir çözüm olabilir [13]. Ancak azınlık sınıflarının örnek sayıları Şekil 2’deki gibi ağı eğitimi için yeterli değilse bu tür veri setlerinde yetersiz örnekleme yapmak sınıflandırma başarımını olumsuz etkileyecektir [14]. Dengesiz veri setlerinde azınlık sınıflarının örnek sayıları sınıflandırma için yetersiz olduğu durumlarda görüntü artırma yöntemleri kullanılarak dengesiz veri seti


dengeli hale getirilmektedir. Veri setini dengeli hale getirebilmek için kernel filtreleri, renk uzayı dönüşümleri, rastgele silme, geometrik dönüşümler, resimlerin karıştırılması gibi temel görüntü işleme yöntemleri kullanıldığı gibi sinirsel sitil aktarımı ve çekişmeli üretici ağlar ile görüntü artırma gibi derin öğrenme yaklaşımları da kullanılmaktadır [7], [15], [16]. Dengesiz görüntü veri setlerinin sebep olduğu sınıflandırma problemlerinin çözümünde görüntü artırma yöntemlerinin daha başarılı sonuçlar vermesini sağlamak için transfer öğrenme yöntemleri ile de desteklenmektedir. Transfer öğrenmede, ImageNet gibi geniş veri setleri ile önceden eğitilmiş olan ağlar, görüntü artırma ile dengeli hale getirilmiş görüntü veri setlerinin sınıflandırılmasında kullanılmaktadır [17], [18]. Transfer öğrenme yöntemlerinden ResNet, VGG, DenseNet, EfficientNet, AlexNet modellerinin görüntü artırma yöntemleri ile dengeli hale getirilmiş dengesiz veri setleri üzerinde başarılı sonuçlar verdiği görülmüştür [19]–[24].

Yapılan çalışmada, literatürde yaygın kullanılan 11 farklı görüntü artırma tekniği tespit edilerek cilt kanseri veri seti üzerinde her bir tekniğin bireysel başarısı evrimsel sinir ağları kullanılarak test edilmiştir. Görüntü artırma tekniklerinin başarısının ölçülmesinde DenseNet50, MobileNet ve DenseNet201 önceden eğitilmiş evrimsel sinir ağı yapıları kullanılmıştır. Yapılan testlerde farklı ağ yapılarında farklı sonuçlar elde edilmiştir. ResNet50 ile yapılan testlerde en yüksek doğruluk oranına 0.967 ile gürültü ekleme yöntemi, DenseNet201 ile yapılan testlerde en yüksek doğruluk oranına 0.965 ile renk uzayı dönüşümü yöntemi, MobileNet ile yapılan testlerde en yüksek doğruluk oranına 0.974 ile resimlerin karıştırılması yöntemi en yüksek doğruluk oranına ulaşmıştır. Her ne kadar kararsız bir durum gibi görüne de her bir ağ yapısına ait karşılaştırma tabloları incelendiğinde bu üç görüntü artırma tekniğinin ilk üç sırada oldukları görülmektedir.

Bu çalışma; giriş, geçmiş çalışmalar, evrimsel sinir ağı, görüntü artırma teknikleri, deneysel çalışmalar ve sonuç şeklinde organize edilmiştir.

2 Geçmiş çalışmalar

Evrimsel sinir ağları ile yapılan sınıflandırma çalışmalarında verilerin ön işleme tabi tutulması, verinin ham haline göre sınıflandırma başarımını etkilemektedir [25]. Sınıflandırma başarımını etkileyebilecek sorunlardan bir tanesi de sınıfların örnek sayıları arasındaki aşırı dengesizliklerdir [26], [27]. Veri setlerindeki sınıfların örnek sayılarının dengelenebilmesi için genel olarak aşırı örnekleme ve yetersiz örnekleme başlıkları altında pek çok çözüm önerisi sunulmuştur. Yuan ve ark. geliştirmiş oldukları yöntemde, görüntü içerisindeki kenarların dış büyüklüğünü kullanan bir aşırı örnekleme yöntemi geliştirmişlerdir. Geliştirdikleri yöntemi veri setleri üzerinde test ederek etkinliğini ortaya koymuşlardır [28]. Jiang ve ark. etiketsiz sınıflar üzerinde aşırı örnekleme yapabilmek için bir kümeleme yöntemi önermişlerdir. Yaptıkları çalışmalarında aynı zamanda çoğunluk sınıflarının örnek sayıları da azaltılmıştır. Geliştirdikleri yöntemini başarımını 44 farklı veri seti üzerinde test etmişlerdir [29].



Şekil 3. Tipik bir evrişimsel sinir ağı [30]

Pek çok çalışmada aşırı örnekleme yöntemi uygulanırken, örnekleme işlemi sadece azınlık sınıfları içerisinde alınan örneklerle yapılmıştır. Temraz ve Keane ise geliştirmiş oldukları yöntemde, k-NN algoritması yardımı ile sadece azınlık sınıfları değil çoğunluk sınıflarındaki örnekleri de kullanan bir aşırı örnekleme yöntemi geliştirmişlerdir [31]. Engelmann ve Lessmann, geliştirmiş oldukları aşırı örnekleme yönteminde çekişmeli üretici ağları (Generative Adversarial Networks-GAN) kullanarak azınlık sınıfları için sentetik örnekler üretmişlerdir. Geliştirilen yöntemi farklı veri setleri üzerinde test ederek yöntemin başarımını test etmişlerdir [32]. Sınıf dengesizliği problemini çözmek için kullanılan yöntemlerden bir kısmı da yetersiz örnekleme konu başlığı altında incelenmektedir. Yetersiz örnekleme yöntemlerinde sınıf dengesizliği probleminin çoğunluk sınıflarının örnek sayıları azaltılarak çözümler geliştirilir. Dai ve ark. geliştirmiş oldukları yetersiz örnekleme yönteminde çoğunluk sınıflarının örnekleri arasındaki benzerlikleri hesaplamışlardır. Örnekler arasındaki benzerlik değerlerine göre bazı örnekleri eleyerek çoğunluk sınıflarının örnek sayılarını azaltmışlardır [27]. Xue ve ark. yapmış oldukları çalışmalarında optimize edilmiş olasılık temelli bir yetersiz örnekleme tekniği geliştirmişlerdir. Geliştirdikleri tekniği, veri setine uygulayarak sınıf dengesizliği probleminin olumsuz etkilerinin çözümüne karşı test etmişlerdir [33].


Nanni ve ark. yapmış oldukları çalışmalarında çevirme, döndürme, yer değiştirme ve kırpma görüntü artırma yöntemlerini VIR, BARK, GRAV ve POR veri setlerine uyguladıktan sonra ResNet50 yapısındaki evrişimsel sinir ağı üzerinde sınıflandırmaya olan etkilerini test etmişlerdir [34]. Perez ve Wang yapmış oldukları çalışmalarında çekişmeli üretici ağlar (GAN) ve döngüsel çekişmeli üretici ağlar (CycleGAN) görüntü artırma teknikleri ile yer değiştirme, kırpma, döndürme, çevirme ve çarpıtma görüntü artırma tekniklerini karşılaştırmışlardır. Bu teknikleri MNIST veri seti üzerinde uyguladıktan sonra VGG16 yapısındaki evrişimsel sinir ağı üzerinde sınıflandırma üzerine etkilerini test etmişlerdir [35]. Bu çalışmada ise, yer değiştirme, döndürme, rastgele silme, gürültü ekleme,

resimlerin karıştırılması, çekirdek filtreleri, çekişmeli üretici ağlar, çevirme, özellik uzayı dönüşümleri, kırpma ve renk uzayı dönüşümleri olmak üzere 11 farklı görüntü artırma tekniği karşılaştırılmıştır. ResNet50, DenseNet201 ve MobileNet önceden eğitilmiş ağları üzerinde sınıflandırma performansları karşılaştırma metriği olarak kullanılmıştır.

3 Evrişimsel sinir ağı (ESA)

Evrişimsel sinir ağı, genellikle görüntüler üzerine uygulanan yapay sinir ağı tabanlı bir derin öğrenme yaklaşımıdır [36]. Bu yapıda, giriş görüntülerinden özellik çıkarım işlemleri ve sadeleştirme işlemleri yapan katmanlar ile birlikte bir de yapay sinir ağı katmanı bulunur [30], [37]. Evrişimsel sinir ağı yapısında bulunan yapay sinir ağı katmanının amacı giriş görüntülerinin doğru şekilde sınıflandırılmasıdır [38]. Yapay sinir ağı, resimlerin sınıflandırılması çalışmalarında yıllardır yaygın şekilde kullanılan bir algoritma olmasına rağmen giriş verilerinin büyük olması durumlarında çok fazla donanımsal kaynağa ihtiyaç duyar [39]. Bu sebeple giriş görüntülerinin, öncelikle özellik çıkarım yöntemleri kullanılarak indirgenmesi ve sınıflandırma başarısını arttıracak şekilde ayırt edici özelliklerin ortaya çıkarılması gerekir [40]. Ancak evrişimsel sinir ağı, yapısında bulundurduğu katmanlar sayesinde özellik çıkarım ve indirgeme işlemlerini dahili olarak yaptığından dolayı giriş görüntüleri üzerinde herhangi bir ön işleme ihtiyaç duymaz [41]. Şekil 3'te tipik bir evrişimsel sinir ağı görülmektedir. Bu ağda giriş görüntüsü, evrişim (Convolution) ve havuzlama (Pooling) katmanlarından geçirilerek özellikleri çıkarılır ve indirgenir. Ardından tamamen bağlı katmana aktarılmak üzere düzeltilir. Tamamen bağlı katman, her bir giriş görüntüsü için olasılıksal sonuçları hesaplar ve çıkış katmanında bulunan aktivasyon fonksiyonu yardımıyla bir çıkış üretir [30], [37]. Evrişim katmanındaki ReLU ise ağın eğitimini olumsuz yönde etkileyen negatif değerleri elimine etmek için kullanılan bir fonksiyondur. Evrişimsel sinir ağı, evrişim, birleştirme ve tamamen bağlı katmanlarında üretilen çıkışlara göre her bir katmanda ayrı ayrı öğrenilme yeteneklerine sahiptir [42]. Evrişimsel sinir ağı yapısının

eğitilebilmesi için çok sayıda görüntüye ihtiyaç duyulur [18]. Her problem için çok sayıda görüntü içeren bir veri seti bulunamayabilir ya da büyük veri setleri ile ağı eğitmek çok miktarda zaman alıyor olabilir. Bu tür durumlarda evrişimsel sinir ağı yapısının ImageNet gibi büyük görüntü veri setleri ile eğitildiği transfer öğrenme yöntemleri kullanılarak hem eğitim zamanından tasarruf edilir hem de yetersiz sayıda görüntü içeren ya da dengesiz veri setleri üzerindeki sınıflandırma başarımı artırılır [17], [19], [24].




Şekil 4. Transfer öğrenme [43]

Şekil 4'te tipik bir transfer öğrenme modeli görülmekte olup literatürde AlexNet, SqueezeNet, VGG16, VGG19, GoogLeNet, ResNet50, ResNet101, InceptionV3 ve InceptionResNetV2 transfer öğrenme modelleri görülmektedir [44].

3.1 Evrişim katmanı

Bu katman, evrişimsel sinir ağı yapısında görüntünün ilk işlendiği katmandır. Görüntüler, piksellerin sayısal değerlerinden oluşan matrisler olarak ele alınır ve özellik haritaları elde edilir. Bu katmanda, görüntüye ait matrisler üzerinde kendisinden daha küçük bir filtre matrisi gezdirilerek özellik haritaları hesaplanır. Bu katmandaki öğrenme işlemi, görüntü üzerinde gezdirilen filtrelerin parametrelerinin sürekli güncellenmesi ile gerçekleşir [45].



Şekil 5. Evrişim katmanı


Şekil 5'te örnek bir evrişim katmanı işlemi görülmektedir. Filtre matrisi görüntüye ait matris üzerinde gezdirilerek görüntüye ait özellikler matris şeklinde elde edilir. Yapılan geri bildirimler vasıtasıyla filtre üzerindeki parametreler güncellenerek bu katmanın öğrenmesi sağlanır.

3.2 Adım (Stride)

Adım, evrişim katmanındaki filtrelerin orijinal görüntü üzerinde kaç piksel kaydırılacağını belirleyen parametredir [46]. Adım değerinin büyütülmesi özellik haritalarının küçülmesine sebep olacaktır. Adım (Stride) işlemi Şekil 6'da görülmektedir.

3.3 Dolgu (Padding)

Bir görüntü evrişim işlemine tabi tutulduğunda boyutu küçülmekte olup bu durum iki farklı olumsuzluğa sebep olmaktadır. Birincisi, küçülen görüntülerdeki bilgi ve detaylar azalmaktadır. İkincisi ise kenar ve köşelerde bulunan piksellerin çıktıya olan etkisinin azalmasıdır [46]. Bu durumda çözüm olarak giriş görüntüsünün dış çeperi 0 değerleri ile doldurularak dolgu (Padding) işlemi yapılır. Yapılan dolgu (Padding) işleminin evrişimsel sinir ağlarında bahsedilen sorunlarla ilgili başarılı sonuçlar verdiği görülmüştür [47].



Şekil 6. Adım işlemi

3.4 ReLU (Rectified linear unit)

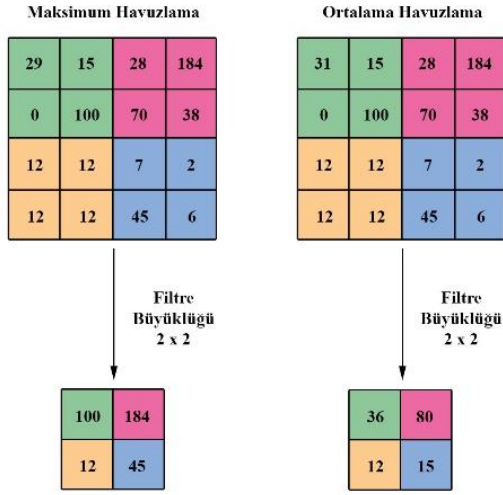
Evrişimsel sinir ağı içerisindeki süreçlerde ağı negatif değerleri öğrenmesini engellemek için kullanılan doğrusal olmayan bir fonksiyondur [48]. ReLU fonksiyonu Denklem (1)'de görülmektedir.

$$f(x) = \max(0, x) \quad (1)$$

3.5 Havuzlama (Pooling) katmanı

Havuzlama katmanı giriş görüntülerine ait matrislerin indirgenmesi amacıyla kullanılır. Bu sayede ağın ihtiyaç duyduğu işlem gücü azalır hem de sınıflandırma başarımına katkısı düşük olan özellikler elimine edilir [49].

Havuzlama katmanında yaygın olarak maksimum havuzlama (Max Pooling) ve ortalama havuzlama (Average Pooling) yöntemlerinden biri kullanılmasına rağmen literatürde çok sayıda havuzlama yöntemi önerilmiştir [50]. Maksimum havuzlama yönteminde seçilen filtre boyutuna (Pool Size) göre filtre içerisinde kalan sayıların en büyüğü alınarak giriş görüntüsü indirgenir. Ortalama havuzlama yönteminde seçilen filtre boyutuna (Pool Size) göre filtre içerisinde kalan sayıların ortalaması alınarak giriş görüntüsü indirgenir [49]. Bahsedilen havuzlama yöntemleri Şekil 7'de görülmektedir.



Şekil 7. Havuzlama katmanı

3.6 Düzleştirme katmanı

Evrişimsel sinir ağının bir parçası olan özellik çıkarım işlemleri bittikten sonra görüntülerin yine bu ağın bir parçası olan yapay sinir ağına aktarılabilmesi için tek boyutlu vektörlere dönüştürülmesi gerekmektedir [51]. Görüntülerin tek boyutlu vektörlere dönüştürüldüğü katmana düzleştirme katmanı adı verilmektedir.

3.7 Tamamen bağlı katman

Giriş görüntüleri üzerinde özellik çıkarım işlemleri tamamlandıktan sonra elde edilen özellik haritaları düzleştirildikten sonra bu katmana gelir. Bu katman, evrişimsel sinir ağı içerisinde bulunan bir yapay sinir ağı yapısıdır [37]. Şekil 3'te görülen bu yapı giriş olarak aldığı özellik haritalarına göre çıkışlar üretir. Bu çıkışlar Softmax gibi aktivasyon fonksiyonları ile işlenerek nihai çıktı elde edilir [52].

4 Görüntü artırma teknikleri

Dengesiz veri setlerindeki azınlık sınıflarının örnek sayılarını artırarak veri setlerini dengeli hale getirebilmek için bu çalışmada kullanılan teknikler Tablo 1'de liste halinde verilmiştir [7].

4.1 Çevirme (Flipping)


Bu işlem, görüntülerin yatayda ya da dikeyde bir eksene göre çevrilmesi işlemidir. Yaygın olarak kullanılan bu yöntemde görüntünün çevrilmiş hali kendisine çok benzediği durumlarda sınıflandırma başarımına düşük olmaktadır [53]. Ayrıca el yazısı gibi görüntülerde çevrilmiş hali başka bir karaktere benzediği durumlarda sınıflandırma hatalarına sebep olabilmektedir [7].

$$(x, y) \rightarrow (x \text{ de\u0131işim}, y \text{ de\u0131işim}) \quad (2)$$

Şekil 8'de örnek bir çevirme işlemi görülmektedir. Bu yöntemde görüntüye ait pikseller Denklem (2)'ye göre herhangi bir eksende aynı uzaklıktaki başka bir konuma taşınır.

Tablo 1. Görüntü artırma teknikleri

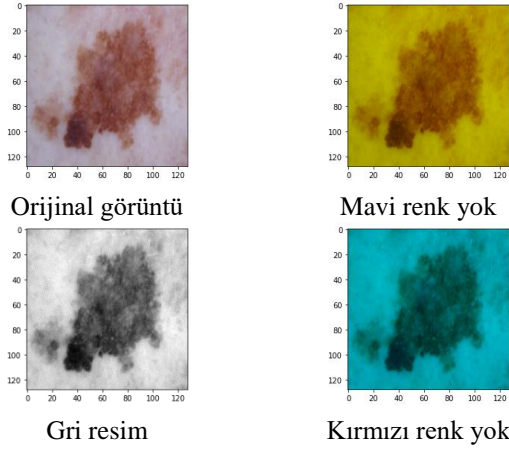
Nu.	Adı	Açıklama
1	Çevirme	Görüntünün bir eksene göre çevrilmesidir
2	Renk dönüşümleri	Görüntü renk kanallarında değişiklikler yapılmasıdır
3	Kırpma	Görüntünün bir bölümünün kırılmasıdır
4	Döndürme	Görüntünün herhangi bir açıda döndürülmesidir
5	Yer de\u0131iştirme	Görüntünün herhangi bir yöne doğru hareket ettirilmesidir
6	Gürültü ekleme	Görüntüye gürültü eklenmesidir
7	Çekirdek filtreleri	Görüntüye filtre matrisleri uygulanmasıdır
8	Resimlerin karıştırılması	Görüntülerin karıştırılmasıdır
9	Rastgele silme	Görüntünün bir bölümünün silinmesidir
10	Özellik dönüşümleri	Görüntü üzerinde vektörel işlemler yapılmasıdır
11	Çekişmeli ağlar	Derin öğrenme ile sentetik görüntü üretimidir



Şekil 8. Görüntülerin çevrilmesi yöntemi ile elde edilen sentetik görüntü örnekleri

4.2 Renk uzayı dönüşümleri (Color space transformations)

Dijital görüntüler genellikle boyutlar (genişlik, yükseklik) ve renk kanallarından (Kırmızı, Yeşil, Mavi) oluşan bir yapıda kodlanırlar. Bu renk kanalları literatürde red, green ve blue kelimelerinin kısaltması olan RGB kısaltması ile yer alır.



Şekil 9. Renk uzayı dönüşümleri ile elde edilen sentetik görüntü örnekleri

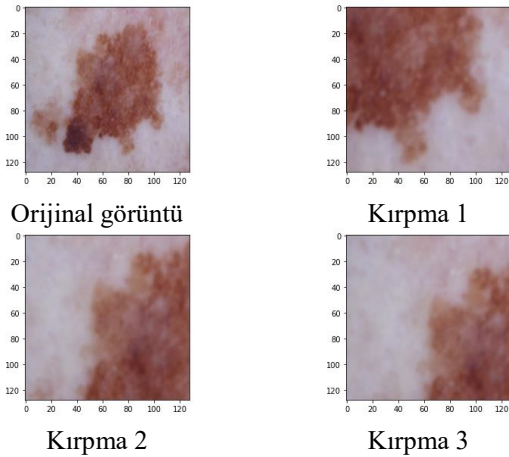
Renk kanalları üzerinde gerçekleştirilen değişikliklerle yapılan görüntü artırma işlemi oldukça pratiktir. Tek kanaldan oluşan bir resme istenilen değerlerden oluşan yeni renk kanalları eklenebilir ya da görüntünün sahip olduğu kırmızı, yeşil, mavi kanallarından bir tanesini diğerlerinden izole ederek hızlı bir şekilde görüntü artırma yapılabilir [7]. Yine kanallar üzerinde yapılabilecek bir başka işlem de görüntünün saydamlığını artırarak ya da azaltarak görüntü artırma yapılabilir [54].

$$Gray = \frac{R + G + B}{3} \quad (3)$$

Ayrıca, Denklem (3)'e göre 3 kanallı red, green, blue (RGB) görüntüleri Gri seviye görüntülere dönüştürülerek görüntü artırma yapılabilir [55]. Örnek renk uzayı dönüşümleri Şekil 9'da görülmektedir.

4.3 Kırpma (Cropping)

Bu yöntemde görüntünün herhangi bir bölgesinden rastgele bir bölüm seçilerek alınır ve veri setine yeni üretilmiş sentetik görüntü olarak eklenir.




Şekil 10. Kırpma yöntemi ile elde edilen sentetik görüntü örnekleri

Şekil 10'da görülmekte olan kırpma işlemi yaygın şekilde kullanılan görüntü artırma yöntemlerinden bir tanesidir. Ancak orijinal görüntüdeki boş bölgelerin kesilip alınarak sentetik görüntü olarak kullanılması durumlarında aşırı öğrenme sorunlarına sebep olabilmektedir [56].


4.4 Döndürme (Rotation)

Bu yöntemde, görüntünün Denklem (4)'e göre sağa ya da sola doğru 1° ile 359° arasında döndürülmesi ile elde edilen yeni görüntüler görüntü artırmada kullanılır. Görüntü artırma amaçlı yaygın şekilde kullanılan bu yöntemde, görüntünün döndürülmüş hali kendisi ile aynı ise sınıflandırma başarımına etkisi düşük olmaktadır [57]. Şekil 11'de görülen bu yöntemde görüntünün döndürüldüğünde farklı görünmesi ya da farklı eksenlerde döndürüldüğünde farklı görüntülere dönüşmesi başarılı sonuçlar verebilmektedir [57].

$$\begin{aligned} (x, y) &\rightarrow (X, Y) \\ X &= \cos(\text{angle}) * x - \sin(\text{angle}) * y \\ Y &= \sin(\text{angle}) * x + \cos(\text{angle}) * y \\ \text{angle} &= \{1^\circ - 359^\circ\} \end{aligned} \quad (4)$$



Şekil 11. Döndürme yöntemi ile elde edilen sentetik görüntü örnekleri



Şekil 12. Yer deęiřtirme yöntemi ile elde edilen sentetik görüntü örnekleri

4.5 Yer deęiřtirme (Translation)

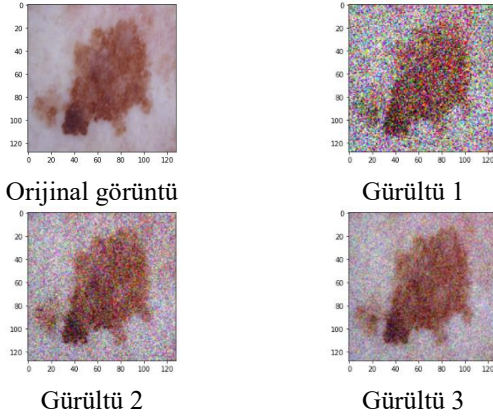
Görüntülerin saęa, sola, ařaęı ya da yukarı doęru kaydırılmaları görüntü artırma için oldukça kullanıřlı olmaktadır. Özellikle veri seti ortalanmıř görüntülerden oluřtuęu durumlarda bu iřlem görüntü artırma için iyi sonuçlar verebilmektedir [58].

$$\begin{aligned} (x, y) &\rightarrow (X, Y) \\ X &= x + dx \\ Y &= y + dy \end{aligned} \quad (5)$$

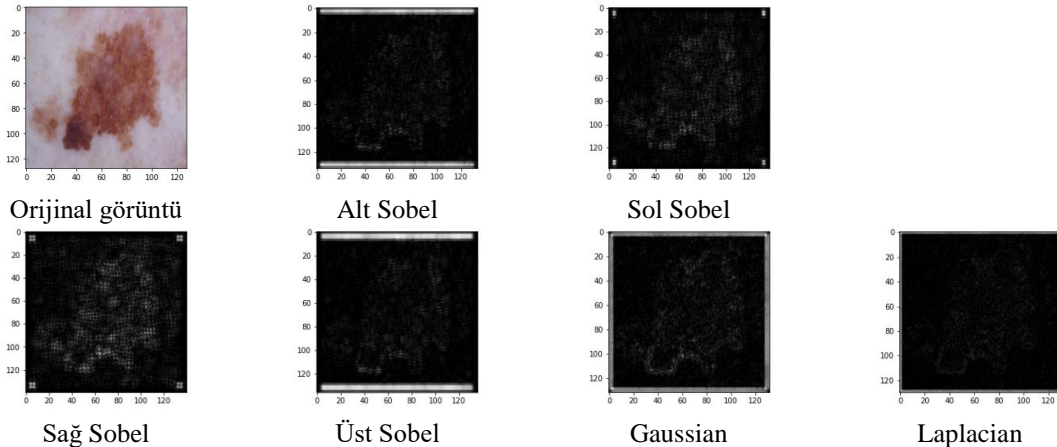
Denklem (5)'te görüntü ierisindeki (x, y) konumunda bulunan bir objenin, yeni konumu olan (X, Y) konumuna tařınması iřlemi grlmektedir. (dx, dy) ise farklı ynleri ifade etmektedir. Yer deęiřtirme iřlemi Denklem (5)'e gre yapılmakta olup Őekil 12'de rnek yer deęiřtirme iřlemleri grlmektedir.

4.6 Grlt ekleme (Noise injection)

Grlt ekleme grntlere rastgele deęerlerle ya da Gaussian Filtresi gibi filtrelerle grlt eklenmesi iřlemidir. Grntlere grlt eklenerek grnt artırma yapılması derin ęrenme algoritmalarının bařarımını arttırmaktadır [59]. Ancak ařırı grlt eklenmesi ya da orijinal grntnn grlt eklendięinde ayırt edici zelliklerini kaybetmesi gibi durumlarda sınıflandırma bařarımını olumsuz ynde etkilemektedir [59].



Őekil 13. Grlt ekleme yntemi ile elde edilen sentetik grnt rnekleri



Őekil 15. ekirdek filtreleri ile elde edilen sentetik grnt rnekleri


Őekil 13'te grlt eklenmiř rnek grnt ve grlt eklenmiř hali grlmektedir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (6)$$

Gaussian Filtresi grntlere Denklem (6)'ya gre eklenmektedir. Denklemde sigma (σ); tm piksellerin standart sapmasını, (x, y) deęerleri; piksellerin konumlarını, e deęeri; Euler sayısını ifade etmektedir.

4.7 ekirdek filtreleri (Kernel filters)

ekirdek filtreleri grnt iřleme yntemleri arasında grntleri keskinleřtirmek ya da bulanıklařtırmak için kullanılan popler yntemlerden biridir. $N \times N$ matrisler halinde grntler zerinde eřitli filtreler kaydırılarak grnt bulanıklařtırılır ya da keskinleřtirilir. Ek olarak, grntlerin keskinleřtirilmesi grnt artırma yntemlerinde kullanıldıęında detayların ne ıkmasını saęlayabilir. Yapılan alıřmalarda ekirdek filtrelerinin sınıflandırmaya olumlu ynde etkileri grlmřtr [60].




Őekil 14. ekirdek filtresi

ekirdek filtreleri evriřimsel sinir aęı katmanları ierisinde de bulunduęundan aęın bařarımını olumsuz ynde etkileyebilmektedir [7]. Literatrde alt (Bottom) sobel, sol (Left) sobel, saę (Right) sobel, st (Top) sobel, gaussian, laplacian ekirdek filtreleri yaygın Őekilde kullanılan filtrelerdir [61], [62]. Bu filtreler Őekil 14'te ki ynteme gre grntlere uygulanarak Őekil 15'teki sonuçlar elde edilmektedir.

4.8 Resimlerin karıştırılması (Mixing images)

Görüntülerin rastgele karıştırılması görüntü artırma yöntemleri açısından mantıksız bir işlemdir. Ancak geliştirilen yöntemlerle resimlerin karıştırılması verimli bir yonteme dönüşebilmektedir [63].



Şekil 16. Resimlerin karıştırılması yöntemi ile elde edilen sentetik görüntü örnekleri

Bu yöntemde, görüntü artırma yapılacak azınlık sınıfı örneklerinin tamamı ya da bir kısmı karıştırılarak sentetik görüntüler elde edilir. Yapılan çalışmada sentetik örnekler her sınıf kendi içerisinde karıştırılarak elde edilmiştir. Şekil 16'da örnek görüntüler görülmektedir.


4.9 Rastgele silme (Random erasing)

Bu yöntemde, görüntü üzerinde belirlenen $N \times M$ boyutlarındaki yama 0- 255 arasındaki piksel değerleriyle, ortalama piksel değerleriyle ya da rastgele piksel değerleriyle maskelenir. Yapılan çalışmalarda rastgele silme yönteminin doğruluk oranını arttırdığı, hata oranını düşürdüğü görülmüştür [64].

Şekil 17'de rastgele silme yöntemi ile belirli bölümlerinden silme işlemi yapılmış görüntü örnekleri görülmektedir.

4.10 Özellik uzayı dönüşümleri (Feature space transformations)

Bu görüntü artırma yönteminde görüntüler $n \times 1$ boyutlarındaki vektörlere dönüştürülür.




Şekil 18. Görüntünün tek boyutlu diziyeye dönüşümü

Şekil 18'de verilen dönüştürme işleminde görüntülerin vektörlere dönüştürülmesiyle bu görüntüler üzerinde pek çok

vektörel operasyon gerçekleştirilebilir. Gerçekleştirilen vektörel operasyonlardan bir tanesi de vektör üzerine Denklem (7)'ye göre gürültü eklemektir [65].

$$C'_i = C_i + \lambda X C'_i \quad (7)$$


Denklem (7)'de C_i orijinal görüntü vektörünü, C'_i sentetik görüntü vektörünü, X gürültü metodunu ve λ gürültü oranını belirtmektedir. Şekil 19'da özellik uzayı dönüşümü ile elde edilmiş görüntüler görülmektedir.




Şekil 17. Rastgele silme yöntemi ile elde edilen sentetik görüntü örnekleri

4.11 Çekişmeli üretici ağlar (Generative Adversarial Network-GAN)

Birbirleri ile çekişme halinde olan iki sinir ağından oluşan bu yapıda, ağlardan bir tanesi sentetik görüntüler oluştururken diğer ağ ise bu görüntülerin gerçek olup olmadığını ayırt etmeye çalışır. Üretici (Generative) ağ gerçeğe daha yakın görüntüler oluşturmayı öğrenirken, ayırt edici ağ ise gerçek görüntüler ile sentetik görüntüleri daha iyi ayırt etmeyi öğrenir. GAN yapısı Şekil 20'de görülmektedir.




Şekil 19. Özellik uzayı dönüşümleri ile elde edilen sentetik görüntü örnekleri



Şekil 20. Çekişmeli üretici ağ [69]

GAN ile üretilen görüntülerin orijinal görüntüden farklı ancak benzer olması sebebiyle dengesiz görüntü veri setlerini dengeli hale getirebilmek için gerekli sentetik görüntüleri elde etmede kullanılabilir [66]. Bu mimarideki üretici ağın ürettiği görüntüleri kullanarak yapılan görüntü artırma yöntemleri başarılı sonuçlar vermektedir [67], [68]. Ancak bazı durumlarda ayırt edici ağın aşırı öğrenmesi sebebiyle birbirine çok benzer görüntüler üretmesi sonucu olarak aşırı öğrenmeye sebep olabilmektedir [66]. Şekil 21’de GAN yöntemi ile elde edilmiş sentetik görüntülerdir.



Şekil 21. Çekişmeli üretici ağlar ile elde edilen sentetik görüntü örnekleri

5 Deneysel çalışmalar

Görüntü artırma yöntemleri kullanılarak veri setlerinin dengeli hale getirilmesi, yaygın şekilde üzerinde çalışılan konu başlıklarından biridir [70]. Görüntü artırma yöntemleri, temel görüntü işleme yöntemleri (Flipping, Mixing, Cropping vs.) ve derin öğrenme tabanlı yaklaşımlar (GAN) olmak üzere iki ana başlık altında incelenmektedir [7]. Bu yöntemlerin test edilebilmesi için yaygın şekilde kullanılan dengesiz veri setleri bulunmaktadır [71], [72]. Bu çalışmada Ham10000 veri seti, bu çalışmada daha önce bahsedilen görüntü artırma teknikleri kullanılarak dengeli hale getirilmiştir. Dengeli hale getirilen veri seti önceden eğitilmiş evrimsel sinir ağları ile test edilmiştir. Önceden eğitilmiş evrimsel sinir ağlarında, ImageNet veri seti ile ağ önceden eğitilerek sınıflandırma başarımının artırılması amaçlanmaktadır. Literatürde bu ağ yapıları yaygın şekilde kullanılmakta ve başarılı sonuçlar elde edilmektedir [43], [73]–[75].

5.1 Veri seti

Literatürde yaygın şekilde görüntü artırma yöntemleri uygulanan dengesiz veri setlerinden bir tanesi de Ham10000 veri setidir [76]. Bu veri setinde, 7 farklı sınıfa bölünmüş halde 10,015 adet renkli deri lezyonu görüntüsü bulunmaktadır.

Ham10000 veri seti, 7 farklı sınıftan oluşmakta olup sınıfların örnek sayılarına bakıldığında dengesiz bir dağılım gösterdiği görülmektedir. Yapılan çalışmada, veri setindeki tüm sınıfların örnek sayıları, 6705 adet ile en fazla sayıda örneğe sahip olan NV sınıfına eşitlenmiştir. Çalışmada kullanılan veri setinin sınıfları ve sınıflar üzerinde yapılacak olan görüntü artırma oranları Tablo 2’de verilmiştir. Tablo 2’de yer alan görüntü artırma oranları (AO) Denklem (8)’e göre, görüntü artırma adetleri (AA) ise Denklem (9)’a göre hesaplanmıştır [77]. Denklem (8) ve (9)’da ÇS; çoğunluk

sınıfı örnek sayısını, AS; azınlık sınıfı örnek sayısını ifade etmektedir.

Tablo 2. Ham10000 veri seti sınıf dağılımı

Sınıf adı	Hastalık adı	Adet	Artırım oranı (%)	Artırım adeti	Görüntü artırımı sonrası adet
MEL	Melanoma	1113	502.42	5592	6705
NV	Nevus	6705	0	0	6705
BCC	Basal cell carcinoma	514	1204.47	6191	6705
AKIEC	Actinic keratosis	327	1950.45	6378	6705
BKL	Bening keratosis	1099	510.1	5606	6705
DF	Dermato fibroma	115	5730.43	6590	6705
VASC	Vascular lesion	142	4621.83	6563	6705
	Toplam	10015		36920	46935

$$AO = \left(\left(\frac{CS}{AS} \right) - 1 \right) \times 100 \quad (8)$$

$$AA = \frac{AO \times (AS)}{100} \quad (9)$$

5.2 Performans değerlendirilmesi

Bu çalışmada, görüntü artırma tekniklerinin sınıflandırma başarımına etkisini değerlendirebilmek için dengesiz bir veri seti üzerinde önceden eğitilmiş evrişimsel sinir ağı yöntemleri kullanılmıştır. Evrişimsel sinir ağları, görüntü veri setleri üzerinde başarılı sonuçlar verse de dengesiz görüntü veri setleri üzerinde başarımı düşmektedir [25], [56]. Evrişimsel sinir ağlarının veri setleri üzerindeki başarımını arttırmak için önceden eğitilmiş ağların kullanılması sonuçları olumlu sonuçlar vermektedir [73], [75], [78]. Ancak veri seti dengeli hale getirildiğinde önceden eğitilmiş ağların veri setinin dengesiz haline göre

daha başarılı sonuçlar verdiği yapılan testlerde görülmüştür. Bu çalışmada ResNet50, DenseNet201 ve MobileNet önceden eğitilmiş ağları kullanılmıştır [79]. Dengeli ve dengesiz veri setleri üzerinde yapılan testler Windows 10 işletim sistemi, Intel Core i7@2.9 GHz işlemci ve 32 GB hafızaya sahip bir bilgisayar üzerinde yapılmıştır. Elde edilen en yüksek ve en düşük sınıflandırma sonuçları koyu renk ile vurgulanmıştır.

5.3 Değerlendirme metrikleri

Evrişimsel sinir ağlarının sınıflandırma sonuçlarının değerlendirilmesi için doğruluk (D), duyarlılık (DY), hassasiyet (HS), yanlış pozitif oranı (YPO), yanlış negatif oranı (YNO) ve F1 skoru (F1) metrikleri kullanılmıştır. Denklem (10)'de verilen D değeri, doğru tahminlerin tüm tahminlere olan oranıdır. Denklem (11)'de verilen HS değeri, doğru pozitif tahminlerin tüm pozitif tahminlere oranıdır. Denklem (12)'de verilen DY değeri, doğru pozitif tahminlerin tüm pozitiflere olan oranıdır. Denklem (13)'de verilen F1 değeri, HS ve DY değerlerinin harmonik ortalamasıdır. Denklem (14)'de verilen YPO değeri, yanlış pozitif tahminlerin tüm negatiflere olan oranıdır. Denklem (15)'te verilen YNO değeri, yanlış negatif tahminlerin tüm pozitiflere olan oranıdır.

$$D = \frac{DP + DN}{DP + DN + YP + YN} \quad (10)$$

$$HS = \frac{DP}{DP + YP} \quad (11)$$

$$DY = \frac{DP}{DP + YN} \quad (12)$$

$$F1 = 2x \frac{HS \times DY}{HS + DY} \quad (13)$$

$$YPO = \frac{YP}{YP + DN} \quad (14)$$

$$YNO = \frac{YN}{YN + DP} \quad (15)$$

5.4 Sınıflandırma sonuçları ve tartışma

Bu çalışmada, öncelikle Ham10000 veri setinde bulunan görüntü örneklerinin çözünürlük değerleri 600x450'den 64x64 çözünürlük değerlerine indirgenmiştir. Veri seti çözünürlüğünün daha düşük bir değere indirgenmesi işlemi özellikle derin öğrenme algoritmalarında gerekli kaynak ihtiyacını düşürdüğünden dolayı yaygın şekilde tercih edilen bir işlemdir [80]. 64x64 çözünürlük değerine indirilen görüntülerden oluşan Ham10000 veri seti bu çalışmada daha önce bahsedilen görüntü artırma teknikleri ile dengeli hale getirilmiştir. Daha sonra veri setinin dengeli hali ve orijinal hali ResNet50, DenseNet201 ve MobileNet önceden eğitilmiş evrişimsel sinir ağları ile test edilmiştir. Önceden eğitilmiş evrişimsel sinir ağlarına ait parametreler Tablo 3'te verilmiştir.

Tablo 3. Resnet50, DenseNet201 ve MobileNet parametreleri

Parametreler	Önceden eğitilmiş evrişimsel sinir ağı yapısı		
	ResNet50	DenseNet201	MobileNet
Giriş	(64x64x3)	(64x64x3)	(64x64x3)
Ağırlıklar	ImageNet ile eğitildi	ImageNet ile eğitildi	ImageNet ile eğitildi
Optimize edici	Adam	Adam	Adam
Kayıp fonksiyonu	Seyrek kategorik çapraz entropi	Seyrek kategorik çapraz entropi	Seyrek kategorik çapraz entropi
Gizli katman aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Çıkış katmanı aktivasyon fonksiyonu	Softmax	Softmax	Softmax
Öğrenme oranı	0.001	0.001	0.001
Devir sayısı	30	30	30

Önceden eğitilmiş evrişimsel sinir ağlarına ait parametrelerin seçiminde optimize edici, kayıp fonksiyonu ve aktivasyon fonksiyonları için ızgara arama yöntemi tercih edilmiştir. Öğrenme oranı ve devir sayısı için ise rastgele arama yöntemi tercih edilmiştir.

Tablo 4. Ham10000 veri setinin dengelenmeden önceki sınıflandırma raporları

Model	D	F1	YPO	YNO
ResNet50	0.716	0.306	0.095	0.718
DenseNet201	0.746	0.542	0.075	0.444
MobileNet	0.784	0.600	0.058	0.439

Tablo 4'te veri setinin dengelenmemiş hali ResNet50, DenseNet201 ve MobileNet önceden eğitilmiş ağları ile test edilerek elde edilen sınıflandırma sonuçları verilmiştir. Elde edilen sonuçlara göre 0.784 doğruluk oranı ile MobileNet ağ yapısı orijinal veri seti üzerinde en yüksek başarı oranına ulaşmıştır.

Veri seti, bu çalışmada incelenen görüntü artırma teknikleri ile ayrı ayrı dengelendikten sonra ResNet50, DenseNet201 ve MobileNet önceden eğitilmiş ağları ile ayrı ayrı test edilmiştir. Elde edilen sınıflandırma sonuçları Tablo 5, Tablo 6 ve Tablo 7'da görülmektedir.

Tablo 5. Görüntü artırma tekniklerinin ResNet50 ile sınıflandırma sonuçları

Teknik	D	F1	YPO	YNO
Yer değiştirme	0.916	0.915	0.013	0.082
Döndürme	0.845	0.846	0.025	0.152
Rastgele silme	0.937	0.938	0.010	0.062
Gürültü ekleme	0.967	0.967	0.005	0.032
Resimlerin karıştırılması	0.945	0.946	0.009	0.053
Çekirdek filtreleri	0.941	0.945	0.009	0.058
Çekişmeli üretici ağ	0.915	0.916	0.014	0.084
Çevirme	0.776	0.776	0.037	0.222
Özellik uzayı dönüşümü	0.927	0.928	0.012	0.071
Kırpma	0.860	0.858	0.023	0.138
Renk uzayı dönüşümü	0.964	0.964	0.005	0.035

Sınıflandırma sonuçları incelendiğinde görüntü artırma tekniklerinin evrişimsel sinir ağları ile sınıflandırma performansını olumlu yönde etkilediği görülmektedir. Veri setinin dengelenmemiş hali bu çalışmada kullanılan önceden eğitilmiş ağlar ile sınıflandırma testlerine tabi tutulduğunda doğruluk oranları %71-78 aralığında yer almaktadır. Veri seti farklı yöntemler ile dengelenerek önceden eğitilmiş ağlar ile sınıflandırma testlerine tabi tutulduğunda ise doğruluk oranları %77-96 aralığında yer almaktadır. ResNet50 ağ yapısı ile yapılan testlere göre 0.967 ile gürültü ekleme yöntemi en yüksek başarı oranına, 0.776 ile çevirme yöntemi en düşük başarı oranına ulaşmıştır.

Tablo 6'da görüldüğü üzere DenseNet201 ile yapılan testlerde 0.965 doğruluk oranı ile renk uzayı dönüşümü yöntemi en yüksek, 0.736 doğruluk oranı ile çevirme yöntemi en düşük başarı oranına ulaşmıştır.

Tablo 6. Görüntü artırma tekniklerinin DenseNet201 ile sınıflandırma sonuçları

Teknik	D	F1	YPO	YNO
Yer değiştirme	0.906	0.906	0.015	0.092
Döndürme	0.806	0.808	0.032	0.190
Rastgele silme	0.933	0.933	0.011	0.066
Gürültü ekleme	0.943	0.944	0.009	0.056
Resimlerin karıştırılması	0.963	0.963	0.006	0.036
Çekirdek filtreleri	0.945	0.945	0.009	0.054
Çekişmeli üretici ağ	0.947	0.947	0.008	0.052
Çevirme	0.736	0.758	0.043	0.260
Özellik uzayı dönüşümü	0.897	0.898	0.017	0.101
Kırpma	0.897	0.897	0.017	0.102
Renk uzayı dönüşümü	0.965	0.965	0.005	0.034

Tablo 7’de görüldüğü üzere MobileNet ile yapılan testlerde ise 0.974 doğruluk oranı ile resimlerin karıştırılması yöntemi en yüksek doğruluk oranına, 0.879 doğruluk oranı ile yer değiştirme yöntemi en düşük başarı oranına ulaşmıştır.

Tablo 7. Görüntü artırma tekniklerinin MobileNet ile sınıflandırma sonuçları

Teknik	D	F1	YPO	YNO
Yer değiştirme	0.879	0.876	0.020	0.118
Döndürme	0.910	0.910	0.014	0.089
Rastgele silme	0.931	0.931	0.011	0.069
Gürültü ekleme	0.972	0.972	0.004	0.027
Resimlerin karıştırılması	0.974	0.974	0.004	0.025
Çekirdek filtreleri	0.949	0.950	0.008	0.049
Çekişmeli üretici ağ	0.946	0.946	0.008	0.053
Çevirme	0.947	0.947	0.008	0.052
Özellik uzayı dönüşümü	0.904	0.903	0.015	0.094
Kırpma	0.896	0.895	0.017	0.103
Renk uzayı dönüşümü	0.969	0.969	0.005	0.030

Tablo 5, 6 ve 7 incelendiğinde farklı görüntü artırma tekniklerinin farklı performanslar sergilediği görülmektedir.

Özellikle Döndürme ve Çevirme tekniklerinde, görüntü üzerinde herhangi bir değişim gerçekleştirilmemesi ve işlem sonucunda elde edilen görüntünün orijinal görüntüye çok benzemesi ihtimalinin yüksek olması bu tekniklerin daha başarısız bir performans sergilemelerine neden olmuştur.

Literatürde, görüntü artırma teknikleri bu çalışmada olduğu gibi her biri yalın halde ya da her biri geliştirilerek kullanılmaktadır [8], [34], [64]. Bunun yanında görüntü artırma tekniklerinden 2 ya da daha fazlası bir araya getirilerek karşılaştırılan yöntemlere göre daha başarılı ya da daha başarısız sonuçlar elde edilebilmektedir, bu durum Tablo 8’de görülmektedir.

Tablo 8 incelendiğinde görüntü artırma tekniklerinin birlikte kullanımında her durumda çok başarılı sonuçlar vermemektedir. Rasheed ve ark. yapmış oldukları çalışmalarında beş farklı tekniği kullanarak ResNetXt101 ağ yapısı ile 0.871 doğruluk oranına ulaşırken, bu çalışmada DenseNet201 ağ yapısı ile veri setine sadece renk uzayı dönüşümü uygulayarak 0.965 doğruluk oranına ulaşmıştır. Bunun yanında, bu çalışmada döndürme ve çevirme teknikleri tek başlarına kullanıldığında en yüksek MobileNet ağ yapısı ile 0.947 doğruluk oranına ulaşılabilirken, Çakmak ve Tenekeci yapmış oldukları çalışmalarında döndürme ve çevirme tekniklerini birlikte kullanarak Nasnet Mobile ağ yapısı ile 0.979 doğruluk oranına ulaşmışlardır.

Tablo 8. 2 ya da daha fazla görüntü artırımı tekniği kullanan çalışmalar

Çalışma	Veri seti	ESA yapısı	Görüntü artırma teknikleri	D
Xin ve ark. [81]	Ham1000	VIT	Çevirme, kırpma, döndürme, renk uzayı dönüşümü	0.941
Benedetti ve ark. [82]	Ham1000	ResNet-v2	Çevirme, yer değiştirme, döndürme, kırpma	0.789
Rasheed ve ark. [83]	Ham1000	ResNet Xt101	GAN, çevirme, döndürme, yer değiştirme, renk uzayı dönüşümü	0.871
Çakmak ve Tenekeci [84]	Ham1000	Nasnet Mobile	Döndürme, çevirme	0.979

6 Sonuç

Dengesiz veri kümelerinin, sınıflandırma algoritmalarını olumsuz etkilediği hem bu çalışmada hem de yapılan diğer çalışmalarda görülmüştür. Bu sorunun çözümü için geliştirilen yöntemlerden bir tanesi de veri kümesini görüntü artırma teknikleri kullanarak dengeli hale getirmektir. Genel olarak görüntü artırma işlemi aşırı örnekleme yöntemleri ile gerçekleştirilmektedir. Ancak aşırı örnekleme

yöntemlerinde benzer örnekler üretmek aşırı öğrenme problemlerine yol açabilir. Bu çalışmada, dengesiz veri seti probleminin çözümü için literatürde yaygın 11 farklı görüntü artırma tekniği Ham10000 veri setine uygulanarak karşılaştırma yapılmıştır. Ayrıca 11 farklı görüntü artırma tekniği ile dengelenmiş veri setleri ResNet50, DenseNet201 ve MobileNet önceden eğitilmiş ağlarını içeren evrimsel sinir ağları üzerinde ayrı ayrı test edilmiş ve karşılaştırmalı sonuçları verilmiştir. Sonuç olarak, aşırı örnekleme yöntemleri Ham10000 veri kümesine uygulandığında performans değerlendirme kriterleri açısından değerlendirildiğinde gürültü ekleme yöntemi belirgin şekilde ResNet50 modelinin, renk uzayı dönüşümü yöntemi DenseNet201 modelinin ve gürültü ekleme yöntemi de MobileNet modelinin sınıflandırma başarısını artırmıştır. Bu çalışmada anlatılan aşırı örnekleme yöntemlerinin çalışma mantıkları analiz edilerek dengesiz veri kümeleri için yeni ya da melez daha etkili aşırı örnekleme yöntemleri önerilebilir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): % 3

Kaynaklar

- [1] M. Šprogar, M. Colnarić, and D. Verber, On data windows for fault detection with neural networks, IFAC-PapersOnLine, vol. 54, no. 4, pp. 38–43, Jan. 2021. doi: 10.1016/j.ifacol.2021.10.007.
- [2] Z. Kayumov, D. Tumakov, and S. Mosin, Hierarchical convolutional neural network for handwritten digits recognition, Procedia Comput Sci, vol. 171, pp. 1927–1934, Jan. 2020. doi: 10.1016/j.procs.2020.04.206.
- [3] F. Luongo, R. Hakim, J. H. Nguyen, A. Anandkumar, and A. J. Hung, Deep learning-based computer vision to recognize and classify suturing gestures in robot-assisted surgery, Surgery (United States), vol. 169, no. 5, pp. 1240–1244, May 2021. doi: 10.1016/j.surg.2020.08.016.
- [4] D. Li, T. Haritunians, E. Mengesha, S. R. Targan, and D. McGovern, Using deeplearning and genetic bigdata to predict crohn's disease, 2019. doi: 10.1016/s0016-5085(19)36864-7.
- [5] O. Russakovsky et al., Imagenet large scale visual recognition challenge, Int J Comput Vis, vol. 115, no. 3, pp. 211–252, Dec. 2015. doi: 10.1007/s11263-015-0816-y/figures/16.
- [6] S. Reshma Prakash and P. Nath Singh, Object detection through region proposal based techniques, Mater Today Proc, vol. 46, pp. 3997–4002, Jan. 2021. doi: 10.1016/j.matpr.2021.02.533.
- [7] C. Shorten and T. M. Khoshgoftaar, A survey on image data augmentation for deep learning, J Big Data, vol. 6, no. 1, pp. 1–48, Dec. 2019. doi: 10.1186/s40537-019-0197-0/figures/33.
- [8] J. Lemley, S. Bazrafkan, and P. Corcoran, Smart augmentation - learning an optimal data augmentation strategy, IEEE Access, vol. 5, pp. 5858–5869, Mar. 2017. doi: 10.1109/access.2017.2696121.
- [9] M. Nagaraju, P. Chawla, S. Upadhyay, and R. Tiwari, Convolution network model based leaf disease detection using augmentation techniques, Expert Syst, vol. 39, no. 4, p. e12885, May 2022. doi: 10.1111/exsy.12885.
- [10] J. M. Haut, M. E. Paoletti, J. Plaza, A. Plaza, and J. Li, Hyperspectral image classification using random occlusion data augmentation, IEEE Geoscience and Remote Sensing Letters, vol. 16, no. 11, pp. 1751–1755, Nov. 2019. doi: 10.1109/lgrs.2019.2909495.
- [11] Z. Li, K. Kamnitsas, and B. Glocker, Analyzing overfitting under class imbalance in neural networks for image segmentation, IEEE Trans Med Imaging, vol. 40, no. 3, pp. 1065–1077, Mar. 2021. doi: 10.1109/tmi.2020.3046692.
- [12] P. Thanapol, K. Lavangnananda, P. Bouvry, F. Pinel, and F. Leprevost, Reducing overfitting and improving generalization in training convolutional neural network (CNN) under limited sample sizes in image recognition, InCIT 2020 - 5th International Conference on Information Technology, pp. 300–305, Oct. 2020. doi: 10.1109/incit50588.2020.9310787.
- [13] W. Lee and K. Seo, Downsampling for binary classification with a highly imbalanced dataset using active learning, Big Data Research, vol. 28, p. 100314, May 2022. doi: 10.1016/j.bdr.2022.100314.
- [14] M. Nagaraju, P. Chawla, and N. Kumar, Performance improvement of deep learning models using image augmentation techniques, Multimed Tools Appl, vol. 81, no. 7, pp. 9177–9200, Mar. 2022. doi: 10.1007/s11042-021-11869-x/tables/10.
- [15] M. John and S. Santhanalakshmi, Image augmentation using GAN models in computer vision, proceedings - 2nd International Conference on Smart Electronics and Communication, ICOSEC 2021, pp. 1194–1201, 2021. doi: 10.1109/icosec51865.2021.9591692.
- [16] D. Vitas, M. Tomic, and M. Burul, Image augmentation techniques for cascade model training, 2018 Zooming Innovation in Consumer Technologies Conference, ZINC 2018, pp. 78–83, Aug. 2018. doi: 10.1109/zinc.2018.8448407.
- [17] G. Chandrashekar, A. Raaza, V. Rajendran, and D. Ravikumar, Side scan sonar image augmentation for sediment classification using deep learning based transfer learning approach, Mater Today Proc, Jul. 2021. doi: 10.1016/j.matpr.2021.07.222.
- [18] M. L. Huang, T. C. Chuang, and Y. C. Liao, Application of transfer learning and image augmentation technology for tomato pest identification, Sustainable Computing: Informatics and Systems, vol. 33, p. 100646, Jan. 2022. doi: 10.1016/j.suscom.2021.100646.
- [19] S. I. Hossain et al., Exploring convolutional neural networks with transfer learning for diagnosing Lyme disease from skin lesion images, Comput Methods Programs Biomed, vol. 215, p. 106624, Mar. 2022. doi: 10.1016/j.cmpb.2022.106624.
- [20] P. Bansal, R. Garg, and P. Soni, Detection of melanoma in dermoscopic images by integrating

- features extracted using handcrafted and deep learning models, *Comput Ind Eng*, vol. 168, p. 108060, Jun. 2022. doi: [10.1016/j.cie.2022.108060](https://doi.org/10.1016/j.cie.2022.108060).
- [21] M. A. Khan, Y. D. Zhang, M. Sharif, and T. Akram, Pixels to Classes: Intelligent learning framework for multiclass skin lesion localization and classification, *Computers & Electrical Engineering*, vol. 90, p. 106956, Mar. 2021. doi: [10.1016/j.compeleceng.2020.106956](https://doi.org/10.1016/j.compeleceng.2020.106956).
- [22] K. Ali, Z. A. Shaikh, A. A. Khan, and A. A. Laghari, Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer, *Neuroscience Informatics*, vol. 2, no. 4, p. 100034, Dec. 2022. doi: [10.1016/j.neuri.2021.100034](https://doi.org/10.1016/j.neuri.2021.100034).
- [23] C. Barata, M. E. Celebi, and J. S. Marques, A survey of feature extraction in dermoscopy image analysis of skin cancer, *IEEE J Biomed Health Inform*, vol. 23, no. 3, pp. 1096–1109, May 2019. doi: [10.1109/jbhi.2018.2845939](https://doi.org/10.1109/jbhi.2018.2845939).
- [24] K. M. Hosny, M. A. Kassem, and M. M. Foaud, Classification of skin lesions using transfer learning and augmentation with Alex-net, *PLoS One*, vol. 14, no. 5, p. e0217293, May 2019. doi: [10.1371/journal.pone.0217293](https://doi.org/10.1371/journal.pone.0217293).
- [25] H. Kim, W. K. Jung, Y. C. Park, J. W. Lee, and S. H. Ahn, Broken stitch detection method for sewing operation using CNN feature map and image-processing techniques, *Expert Syst Appl*, vol. 188, p. 116014, Feb. 2022. doi: [10.1016/j.eswa.2021.116014](https://doi.org/10.1016/j.eswa.2021.116014).
- [26] P. Baro and M. D. Borah, A factor based multiple imputation approach to handle class imbalance, *Procedia Comput Sci*, vol. 218, pp. 103–112, Jan. 2023. doi: [10.1016/j.procs.2022.12.406](https://doi.org/10.1016/j.procs.2022.12.406).
- [27] Q. Dai, J. wei Liu, and Y. hui Shi, Class-overlap undersampling based on Schur decomposition for Class-imbalance problems, *Expert Syst Appl*, vol. 221, p. 119735, Jul. 2023. doi: [10.1016/j.eswa.2023.119735](https://doi.org/10.1016/j.eswa.2023.119735).
- [28] X. Yuan, S. Chen, H. Zhou, C. Sun, and L. Yuwen, CHSMOTE: Convex hull-based synthetic minority oversampling technique for alleviating the class imbalance problem, *Inf Sci (N Y)*, vol. 623, pp. 324–341, Apr. 2023. doi: [10.1016/j.ms.2022.12.056](https://doi.org/10.1016/j.ms.2022.12.056).
- [29] Z. Jiang, L. Zhao, Y. Lu, Y. Zhan, and Q. Mao, A semi-supervised resampling method for class-imbalanced learning, *Expert Syst Appl*, vol. 221, p. 119733, Jul. 2023. doi: [10.1016/j.eswa.2023.119733](https://doi.org/10.1016/j.eswa.2023.119733).
- [30] F. Sultana, A. Sufian, and P. Dutta, Evolution of image segmentation using deep convolutional neural network: a survey, *Knowl Based Syst*, vol. 201–202, p. 106062, Aug. 2020. doi: [10.1016/j.knosys.2020.106062](https://doi.org/10.1016/j.knosys.2020.106062).
- [31] M. Temraz and M. T. Keane, Solving the class imbalance problem using a counterfactual method for data augmentation, *Machine Learning with Applications*, vol. 9, p. 100375, Sep. 2022. doi: [10.1016/j.mlwa.2022.100375](https://doi.org/10.1016/j.mlwa.2022.100375).
- [32] J. Engelmann and S. Lessmann, Conditional wasserstein gan-based oversampling of tabular data for imbalanced learning, *Expert Syst Appl*, vol. 174, p. 114582, Jul. 2021. doi: [10.1016/j.eswa.2021.114582](https://doi.org/10.1016/j.eswa.2021.114582).
- [33] S. Xue et al., 2D probabilistic undersampling pattern optimization for MR image reconstruction, *Med Image Anal*, vol. 77, p. 102346, Apr. 2022. doi: [10.1016/j.media.2021.102346](https://doi.org/10.1016/j.media.2021.102346).
- [34] L. Nanni, M. Paci, S. Brahnem, and A. Lumini, Comparison of different image data augmentation approaches, *Journal of Imaging* 2021, Vol. 7, Page 254, vol. 7, no. 12, p. 254, Nov. 2021. doi: [10.3390/jimaging7120254](https://doi.org/10.3390/jimaging7120254).
- [35] L. Perez and J. Wang, The Effectiveness of data augmentation in image classification using deep learning, Dec. 2017, Accessed: May 25, 2023. [Online]. available: <https://arxiv.org/abs/1712.04621v1>
- [36] M. V. Valueva, N. N. Nagornov, P. A. Lyakhov, G. V. Valuev, and N. I. Chervyakov, Application of the residue number system to reduce hardware costs of the convolutional neural network implementation, *Math Comput Simul*, vol. 177, pp. 232–243, Nov. 2020. doi: [10.1016/j.matcom.2020.04.031](https://doi.org/10.1016/j.matcom.2020.04.031).
- [37] J. X. Mi, J. Feng, and K. Y. Huang, Designing efficient convolutional neural network structure: A survey, *Neurocomputing*, vol. 489, pp. 139–156, Jun. 2022. doi: [10.1016/j.neucom.2021.08.158](https://doi.org/10.1016/j.neucom.2021.08.158).
- [38] S. Kalra and A. Leekha, Survey of convolutional neural networks for image captioning, *Journal of Information and Optimization Sciences*, vol. 41, no. 1, pp. 239–260, Jan. 2020. doi: [10.1080/02522667.2020.1715602](https://doi.org/10.1080/02522667.2020.1715602).
- [39] S. Ding, H. Zhu, W. Jia, and C. Su, A survey on feature extraction for pattern recognition, *Artif Intell Rev*, vol. 37, no. 3, pp. 169–180, Mar. 2012. doi: [10.1007/s10462-011-9225-y](https://doi.org/10.1007/s10462-011-9225-y).
- [40] T. Kavzoglu and P. M. Mather, The role of feature selection in artificial neural network applications, *Int J Remote Sens*, vol. 23, no. 15, pp. 2919–2937, 2002. doi: [10.1080/01431160110107743](https://doi.org/10.1080/01431160110107743).
- [41] A. Ferreira and G. Giralaldi, Convolutional neural network approaches to granite tiles classification, *Expert Syst Appl*, vol. 84, pp. 1–11, Oct. 2017. doi: [10.1016/j.eswa.2017.04.053](https://doi.org/10.1016/j.eswa.2017.04.053).
- [42] P. Witonchart and P. Chongstitvatana, Application of structured support vector machine backpropagation to a convolutional neural network for human pose estimation, *Neural Networks*, vol. 92, pp. 39–46, Aug. 2017. doi: [10.1016/j.neunet.2017.02.005](https://doi.org/10.1016/j.neunet.2017.02.005).
- [43] A. Deshpande, V. V. Estrela, and P. Patavardhan, The DCT-CNN-ResNet50 architecture to classify brain tumors with super-resolution, convolutional neural network, and the ResNet50, *Neuroscience Informatics*, vol. 1, no. 4, p. 100013, Dec. 2021. doi: [10.1016/j.neuri.2021.100013](https://doi.org/10.1016/j.neuri.2021.100013).
- [44] M. Ebrahim, M. Al-Ayyoub, and M. A. Alsmirat, Will transfer learning enhance imagenet classification accuracy using imagenet-pretrained models?, 2019 10th International Conference on Information and

- Communication Systems, ICICS 2019, pp. 211–216, Jun. 2019. doi: [10.1109/iacs.2019.8809114](https://doi.org/10.1109/iacs.2019.8809114).
- [45] S. ur Rehman et al., Unsupervised pre-trained filter learning approach for efficient convolution neural network, *Neurocomputing*, vol. 365, pp. 171–190, Nov. 2019. doi: [10.1016/j.neucom.2019.06.084](https://doi.org/10.1016/j.neucom.2019.06.084).
- [46] L. Zaniolo and O. Marques, On the use of variable stride in convolutional neural networks, *Multimed Tools Appl*, vol. 79, no. 19–20, pp. 13581–13598, May 2020. doi: [10.1007/s11042-019-08385-4/metrics](https://doi.org/10.1007/s11042-019-08385-4/metrics).
- [47] A. D. Nguyen, S. Choi, W. Kim, S. Ahn, J. Kim, and S. Lee, Distribution padding in convolutional neural networks, *Proceedings - International Conference on Image Processing, ICIP*, vol. 2019-September, pp. 4275–4279, Sep. 2019. doi: [10.1109/icip.2019.8803537](https://doi.org/10.1109/icip.2019.8803537).
- [48] . F. Agarap, Deep learning using rectified linear units (ReLU), Mar. 2018. doi: [10.48550/arxiv.1803.08375](https://doi.org/10.48550/arxiv.1803.08375).
- [49] Z. Song et al., A sparsity-based stochastic pooling mechanism for deep convolutional neural networks, *Neural Networks*, vol. 105, pp. 340–345, Sep. 2018. doi: [10.1016/j.neunet.2018.05.015](https://doi.org/10.1016/j.neunet.2018.05.015).
- [50] A. Zafar et al., A comparison of pooling methods for convolutional neural networks, *Applied Sciences* 2022, Vol. 12, Page 8643, vol. 12, no. 17, p. 8643, Aug. 2022. doi: [10.3390/app12178643](https://doi.org/10.3390/app12178643).
- [51] W. S. Yang, Y. C. Feng, and T. Y. Liang, An image quality predictor based on convolution neural networks, *ISPAACS 2021 - International Symposium on Intelligent Signal Processing and Communication Systems: 5G Dream to Reality*, Proceeding, 2021. doi: [10.1109/ispacs51563.2021.9651075](https://doi.org/10.1109/ispacs51563.2021.9651075).
- [52] A. Bilal, G. Sun, and S. Mazhar, Finger-vein recognition using a novel enhancement method with convolutional neural network, *Journal of Chinese Institute of Engineers*, vol. 44, no. 5, pp. 407–417, 2021. doi: [10.1080/02533839.2021.1919561](https://doi.org/10.1080/02533839.2021.1919561).
- [53] N. Srivastava, G. Hinton, A. Krizhevsky, and R. Salakhutdinov, Dropout: a simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, vol. 15, pp. 1929–1958, 2014. doi: [10.5555/2627435](https://doi.org/10.5555/2627435).
- [54] C. Liu, Y. Liang, and W. Wen, Fire image augmentation based on diverse alpha compositing for fire detection, *Proceedings - 2022 15th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics, CISP-BMEI 2022*, 2022. doi: [10.1109/cisp-bmei56279.2022.9979846](https://doi.org/10.1109/cisp-bmei56279.2022.9979846).
- [55] J. Wang and S. Lee, Data augmentation methods applying grayscale images for convolutional neural networks in machine vision, *Applied Sciences (Switzerland)*, vol. 11, no. 15, Aug. 2021. doi: [10.3390/app11156721](https://doi.org/10.3390/app11156721).
- [56] R. Takahashi, T. Matsubara, and K. Uehara, Data augmentation using random image cropping and patching for deep CNNs, *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 30, no. 9, pp. 2917–2931, Sep. 2020. doi: [10.1109/tcsvt.2019.2935128](https://doi.org/10.1109/tcsvt.2019.2935128).
- [57] N. Tajbakhsh, M. B. Gotway, and J. Liang, Computer-aided pulmonary embolism detection using a novel vessel-aligned multi-planar image representation and convolutional neural networks, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9350, pp. 62–69, 2015. doi: [10.1007/978-3-319-24571-3_8/cover](https://doi.org/10.1007/978-3-319-24571-3_8/cover).
- [58] A. Gupta, S. Venkatesh, S. Chopra, and C. Ledig, Generative image translation for data augmentation of bone lesion pathology, *Proceedings of Machine Learning Research*, vol. 102. PMLR, pp. 225–235, May 24, 2019. Accessed: Dec. 31, 2022. [Online]. available: <https://proceedings.mlr.press/v102/gupta19b.html>
- [59] F. J. Moreno-Barea, F. Strazzera, J. M. Jerez, D. Urda, and L. Franco, Forward noise adjustment scheme for data augmentation, *Proceedings of the 2018 IEEE Symposium Series on Computational Intelligence, SSCI 2018*, pp. 728–734, Jan. 2019. doi: [10.1109/ssci.2018.8628917](https://doi.org/10.1109/ssci.2018.8628917).
- [60] G. Kang, X. Dong, L. Zheng, and Y. Yang, PatchShuffle regularization, Jul. 2017, Accessed: Dec. 31, 2022. [Online]. available: https://www.researchgate.net/publication/318670749_patchshuffle_regularization
- [61] N. Nausheen, A. Seal, P. Khanna, and S. Halder, A FPGA based implementation of Sobel edge detection, *Microprocess Microsyst*, vol. 56, pp. 84–91, Feb. 2018. doi: [10.1016/j.micpro.2017.10.011](https://doi.org/10.1016/j.micpro.2017.10.011).
- [62] T. Ma et al., Optimized Laplacian image sharpening algorithm based on graphic processing unit, *Physica A: Statistical Mechanics and its Applications*, vol. 416, pp. 400–410, Dec. 2014. doi: [10.1016/j.physa.2014.09.026](https://doi.org/10.1016/j.physa.2014.09.026).
- [63] H. Inoue, Data Augmentation by Pairing Samples for Images Classification, *ICLR 2018 Conference*, ArXiv, 2018. doi: [10.48550/arxiv.1801.02929](https://doi.org/10.48550/arxiv.1801.02929)
- [64] . Saran, F. Nar, and A. N. Saran, Perlin random erasing for data augmentation, *SIU 2021 - 29th IEEE Conference on Signal Processing and Communications Applications*, Proceedings, Jun. 2021. doi: [10.1109/siu53274.2021.9477804](https://doi.org/10.1109/siu53274.2021.9477804).
- [65] S. Ozair and Y. Bengio, Deep Directed Generative Autoencoders, Oct. 2014, Accessed: Dec. 31, 2022. [Online]. available: https://www.researchgate.net/publication/313857747_dataset_augmentation_in_feature_space
- [66] C. Dewi, R. C. Chen, Y. T. Liu, and H. Yu, Various generative adversarial networks model for synthetic prohibitory sign image generation, *Applied Sciences (Switzerland)*, vol. 11, no. 7, Apr. 2021. doi: [10.3390/app11072913](https://doi.org/10.3390/app11072913).
- [67] L. van der Maaten and G. Hinton, Visualizing data using t-SNE, *Journal of Machine Learning Research*, vol. 9, no. 86, pp. 2579–2605, 2008, Accessed: Dec.

- 31, 2022. [Online]. available: <http://jmlr.org/papers/v9/vandermaaten08a.html>
- [68] V. Sandfort, K. Yan, P. J. Pickhardt, and R. M. Summers, Data augmentation using generative adversarial networks (CycleGAN) to improve generalizability in CT segmentation tasks, *Scientific Reports* 2019 9:1, vol. 9, no. 1, pp. 1–9, Nov. 2019. doi: [10.1038/s41598-019-52737-x](https://doi.org/10.1038/s41598-019-52737-x).
- [69] Z. Qin, Z. Liu, P. Zhu, and Y. Xue, A GAN-based image synthesis method for skin lesion classification, *Comput Methods Programs Biomed*, vol. 195, p. 105568, Oct. 2020. doi: [10.1016/j.cmpb.2020.105568](https://doi.org/10.1016/j.cmpb.2020.105568).
- [70] N. E. Khalifa, M. Loey, and S. Mirjalili, A comprehensive survey of recent trends in deep learning for digital images augmentation, *Artif Intell Rev*, vol. 55, no. 3, pp. 2351–2377, Mar. 2022. doi: [10.1007/s10462-021-10066-4/tables/5](https://doi.org/10.1007/s10462-021-10066-4/tables/5).
- [71] V. Srivastava, D. Kumar, and S. Roy, A median based quadrilateral local quantized ternary pattern technique for the classification of dermatoscopic images of skin cancer, *Computers and Electrical Engineering*, vol. 102, p. 108259, Sep. 2022. doi: [10.1016/j.compeleceng.2022.108259](https://doi.org/10.1016/j.compeleceng.2022.108259).
- [72] K. S. Sudeep and K. K. Pal, Preprocessing for image classification by convolutional neural networks, 2016 IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology, RTEICT 2016 - Proceedings, pp. 1778–1781, Jan. 2017. doi: [10.1109/rteict.2016.7808140](https://doi.org/10.1109/rteict.2016.7808140).
- [73] M. H. Rahman, M. K. A. Jannat, M. S. Islam, G. Grossi, S. Bursic, and M. Aktaruzzaman, Real-time face mask position recognition system based on MobileNet model, *Smart Health*, p. 100382, Jan. 2023. doi: [10.1016/j.smhl.2023.100382](https://doi.org/10.1016/j.smhl.2023.100382).
- [74] M. S. H. Talukder and A. K. Sarkar, Nutrients deficiency diagnosis of rice crop by weighted average ensemble learning, *Smart Agricultural Technology*, vol. 4, p. 100155, Aug. 2023. doi: [10.1016/j.atech.2022.100155](https://doi.org/10.1016/j.atech.2022.100155).
- [75] G. S. Nijaguna, J. A. Babu, B. D. Parameshachari, R. P. de Prado, and J. Frnda, Quantum Fruit Fly algorithm and ResNet50-VGG16 for medical diagnosis, *Appl Soft Comput*, vol. 136, p. 110055, Mar. 2023. doi: [10.1016/j.asoc.2023.110055](https://doi.org/10.1016/j.asoc.2023.110055).
- [76] P. Tschandl, The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. Harvard Dataverse, 2018. doi: [10.7910/dvn/dbw86t](https://doi.org/10.7910/dvn/dbw86t).
- [77] M. H. Ibrahim, ODBOT: Outlier detection-based oversampling technique for imbalanced datasets learning, *Neural Comput Appl*, vol. 33, no. 22, pp. 15781–15806, Nov. 2021. doi: [10.1007/s00521-021-06198-x/tables/17](https://doi.org/10.1007/s00521-021-06198-x/tables/17).
- [78] P. Carcagnì et al., Classification of skin lesions by combining multilevel learnings in a DenseNet architecture, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11751 LNCS, pp. 335–344, 2019. doi: [10.1007/978-3-030-30642-7_30/cover](https://doi.org/10.1007/978-3-030-30642-7_30/cover).
- [79] A. Sharma and P. K. Mishra, Covid-MANet: Multi-task attention network for explainable diagnosis and severity assessment of COVID-19 from CXR images, *Pattern Recognit*, vol. 131, p. 108826, Nov. 2022. doi: [10.1016/j.patcog.2022.108826](https://doi.org/10.1016/j.patcog.2022.108826).
- [80] T. Gangavarapu and N. Patil, A novel filter–wrapper hybrid greedy ensemble approach optimized using the genetic algorithm to reduce the dimensionality of high-dimensional biomedical datasets, *Appl Soft Comput*, vol. 81, p. 105538, Aug. 2019. doi: [10.1016/j.asoc.2019.105538](https://doi.org/10.1016/j.asoc.2019.105538).
- [81] C. Xin et al., An improved transformer network for skin cancer classification, *Comput Biol Med*, vol. 149, p. 105939, 2022. doi: [10.1016/j.combiomed.2022.105939](https://doi.org/10.1016/j.combiomed.2022.105939).
- [82] P. Benedetti, D. Perri, M. Simonetti, O. Gervasi, G. Reali, and M. Femminella, Skin cancer classification using inception network and transfer learning, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 12249 LNCS, pp. 536–545, Nov. 2021. doi: [10.1007/978-3-030-58799-4_39](https://doi.org/10.1007/978-3-030-58799-4_39).
- [83] A. Rasheed, A. Iqbal Umar, S. Hamad Shirazi, Z. Khan, S. Nawaz, and M. Shahzad, Automatic eczema classification in clinical images based on hybrid deep neural network, *Comput Biol Med*, vol. 147, p. 105807, 2022. doi: [10.1016/j.combiomed.2022.105807](https://doi.org/10.1016/j.combiomed.2022.105807).
- [84] M. Cakmak and M. E. Tenekeci, Melanoma detection from dermoscopy images using Nasnet Mobile with transfer learning, *SIU 2021 - 29th IEEE Conference on Signal Processing and Communications Applications, Proceedings*, Jun. 2021. doi: [10.1109/siu53274.2021.9477985](https://doi.org/10.1109/siu53274.2021.9477985).

