

Veri Artırmanın CNN Tabanlı Derin Sinir Ağı Modellerine Etkisi

Kadir KESGİN*

¹Bilgisayar Teknolojileri Bölümü / Gönen MYO, Bandırma Onyedi Eylül Üniversitesi, Türkiye

*(kadir@bandirma.edu.tr)

(Received: 30 April 2025, Accepted: 07 May 2025)

(4th International Conference on Scientific and Innovative Studies ICSIS 2025, April 29-30, 2025)

ATIF/REFERENCE: Kesgin, K. (2025). Veri Artırmanın CNN Tabanlı Derin Sinir Ağı Modellerine Etkisi. *International Journal of Advanced Natural Sciences and Engineering Researches*, 9(5), 119-122.

Özet – Bu çalışmada, veri artırma tekniklerinin Convolutional Neural Network (CNN) tabanlı görüntü sınıflandırma modellerinin performansı üzerindeki etkileri araştırılmıştır. Özellikle sınırlı veri setlerinde modelin genelleme yeteneğini artırmak amacıyla veri artırmanın sunduğu katkılar detaylı bir şekilde analiz edilmiştir. Çalışmada CIFAR-10 veri seti kullanılarak iki farklı senaryo uygulanmıştır: veri artırmaz ve veri artırmalı eğitim. Veri artırma işlemleri arasında yatay çevirme, rastgele döndürme, kırpma ve parlaklık-kontrast değişimleri gibi temel teknikler bulunmaktadır. Model, Adam optimizasyon algoritması ve çapraz entropi kayıp fonksiyonu kullanılarak eğitilmiştir. Eğitim sürecinde epoch bazında kayıp değerleri ve doğruluk oranları takip edilmiş, elde edilen sonuçlar veri artırmanın model performansını önemli ölçüde iyileştirdiğini ortaya koymuştur. Veri artırmalı eğitim sonucunda doğrulama doğruluğu %71'den %83'e yükselmiş ve doğrulama kaybı ciddi ölçüde azalmıştır. Ayrıca eğitim sırasında overfitting etkisinin de önemli ölçüde azaldığı gözlemlenmiştir. Sonuçlar, veri artırmanın küçük veri setleriyle çalışan CNN modelleri için kritik bir iyileştirme stratejisi olduğunu doğrulamaktadır. Gelecek çalışmalarda daha karmaşık veri artırma yöntemlerinin ve farklı CNN mimarilerinin etkileri araştırılabilir.

Anahtar Kelimeler – CNN, Veri Artırma, Görüntü Sınıflandırma, Derin Öğrenme, Model Performansı

I. GİRİŞ

Derin öğrenme sistemleri, özellikle görsel tanıma, sınıflandırma ve nesne tespiti gibi alanlarda devrim niteliğinde başarılar elde etmiştir. Convolutional Neural Networks (CNN), görüntülerdeki lokal özellikleri öğrenme kapasitesi ile bu gelişmelerin merkezinde yer almaktadır (Taylor & Nitschke, 2018). Ancak, derin öğrenme modellerinin başarısı büyük ölçüde büyük, dengeli ve çeşitli veri setlerinin varlığına bağlıdır. Gerçek dünyada bu tür veri setlerine ulaşmak zor olduğundan, veri artırma (data augmentation) teknikleri, özellikle az veri ile yüksek doğruluk hedeflenen durumlarda vazgeçilmez hale gelmiştir (Claro et al., 2022). Bu çalışmada, CNN tabanlı görüntü sınıflandırma modelinde uygulanan veri artırma tekniklerinin doğruluk, kayıp değeri ve genelleme başarısı üzerindeki etkileri araştırılmaktadır.

II. MATERYAL VE YÖNTEM

Bu çalışmada, görüntü sınıflandırma problemi üzerinde veri artırma tekniklerinin etkisini incelemek amacıyla, yaygın olarak kullanılan CIFAR-10 veri seti üzerinde Convolutional Neural Network (CNN) tabanlı bir model inşa edilmiştir. Tüm deneyler PyTorch framework'ü kullanılarak gerçekleştirilmiştir.

III. DENEYSEL SONUÇLAR


Deneyler, veri artırmanın model performansına belirgin katkılar sunduğunu ortaya koymuştur. Veri artırmaz eğitimde doğruluk oranı ortalama %71 civarında kalırken, veri artırmalı eğitimde bu oran %83'e

kadar yükselmiştir. Kaynaklarda belirtildiği gibi, artırma teknikleri sadece doğruluk oranını artırmakla kalmaz, aynı zamanda overfitting'i azaltarak modelin genelleme yeteneğini artırır (Bjerrum et al., 2017; Monshi et al., 2021). Çalışmada veri artırılmalı ve artırmaz eğitim senaryoları için model performansları Tablo 1'de karşılaştırılmıştır. Elde edilen sonuçlar, veri artırmanın doğruluk oranlarını ve kayıp değerlerini olumlu yönde etkilediğini göstermektedir. Modelin eğitim süreci boyunca kaydedilen kayıp (loss) değerleri ve test veri seti üzerindeki doğruluk oranları analiz edilmiştir.

Tablo 1. Veri Artırılmalı ve Artırmaz Eğitim Senaryolarında CNN Model Performans Karşılaştırması


Metrik	Veri Artırmaz	Veri Artırılmalı
Eğitim Doğruluğu	%82	%90
Doğrulama Doğruluğu	%71	%83
Doğrulama Kaybı	0.84	0.47

Şekil 1'de görüldüğü üzere, modelin eğitim kaybı epoch ilerledikçe düzenli olarak azalmıştır. Bu durum, modelin eğitim verileri üzerindeki öğrenme sürecinin başarıyla gerçekleştiğini ve optimizasyonun etkin çalıştığını göstermektedir.



Şekil 1. CNN Modelinin Epoch Bazında Eğitim Kaybı

Eğitim verileri üzerinde yapılan artırımların etkisi, test veri seti üzerindeki doğruluk oranlarında da belirgin bir şekilde gözlemlenmiştir. Şekil 2'de gösterildiği gibi, başlangıçta %58.4 olan test doğruluğu eğitim ilerledikçe sürekli bir artış göstermiş ve 10. epoch sonunda %81.0 seviyesine ulaşmıştır. Bu sonuçlar, veri artırma stratejilerinin modelin genelleme yeteneğini artırdığına dair literatürdeki bulgularla uyumludur (Shorten & Khoshgoftaar, 2019; Monshi et al., 2021).



Şekil 2. Veri Artırılmalı CNN Modelinin Test Doğruluğu

Bu sonuçlar ayrıca, az veri ile çalışan projelerde veri artırmanın performans iyileştirici etkisinin ne kadar kritik olduğunu bir kez daha doğrulamaktadır (Claro et al., 2022).

A. Veri Seti: CIFAR-10

CIFAR-10, 10 farklı sınıfta (uçak, otomobil, kuş, kedi, geyik, köpek, kurbağa, at, gemi, kamyon) toplam 60.000 renkli görüntüden oluşan bir veri setidir; bunlardan 50.000 tanesi eğitim, 10.000 tanesi test amacıyla

kullanılır (Krizhevsky et al., 2012). Görüntülerin 32x32 piksel olması, bu veri setini özellikle hızlı prototipleme için uygun kılmaktadır. Görüntüler küçük ve düşük çözünürlüklü olduğundan, sınıflar arasındaki ayrımı öğrenmek kolay değildir; bu da modelin genelleme kabiliyetine yönelik çalışmaları anlamlı hale getirir (Claro et al., 2022).

B. CNN Model Mimarisi

Convolutional Neural Networks (CNN'ler), yerel yapılar üzerinden öğrenme gerçekleştirebilen ve özellikle görsel verilerde başarılı sonuçlar elde eden mimarilerdir (Goodfellow et al., 2016). Bu çalışmada kullanılan model, aşağıdaki katmanlardan oluşmaktadır:

Konvolüsyon Katmanları: İlk iki katmanda sırasıyla 32 ve 64 filtreli 3x3 çekirdekler uygulanmış; ReLU aktivasyon fonksiyonu kullanılmıştır. Bu yapı, görsellerdeki düşük seviyeli (kenar, renk geçişi vb.) özelliklerin öğrenilmesini sağlar.

Havuzlama (Max Pooling): 2x2 boyutlu alt örnekleme işlemi, boyutları küçültürken öznitelik yoğunluğunu korur (Aquino et al., 2017).

Dropout Katmanı: %25 oranında dropout uygulanarak aşırı öğrenmenin (overfitting) önüne geçilmesi hedeflenmiştir (Srivastava et al., 2014).

Tam Bağlantılı Katmanlar: Özellik haritaları düzleştirilerek 512 nöronlu bir katmana bağlanır ve son katman softmax ile 10 sınıfa karar verir.

Kullanılan kod örnekleri Şekil 3 te gösterilmiştir.

C. Eğitim Parametreleri

Model, Adam optimizasyon algoritması ile 30 epoch boyunca batch size 64 olacak şekilde eğitilmiştir. Adam, öğrenme oranı adaptasyonu sağlayarak daha hızlı yakınsama sunan bir optimizasyon algoritmasıdır (Kingma & Ba, 2015). Kayıp fonksiyonu olarak cross-entropy loss kullanılmıştır, çünkü çok sınıflı sınıflandırma problemlerinde yaygın olarak tercih edilmektedir.

D. Veri Artırma Teknikleri

Veri artırma (Data Augmentation), sınırlı veriyle daha zengin bir dağılım elde etmek için orijinal görüntüler üzerinde yapılan dönüşüm ve bozulmalardır. Bu çalışmada aşağıdaki artırma işlemleri uygulanmıştır:

Yatay Çevirme (Horizontal Flip): Görsellerin simetrik versiyonları ile çeşitlilik oluşturur.

Döndürme (Rotation): Görüntüler $\pm 15^\circ$ arasında döndürülerek pozisyon değişimlerine karşı modelin duyarlılığı artırılır.

Parlaklık ve Kontrast Ayarı: Görüntülerin ışık ve renk varyasyonlarına karşı dayanıklılığı artırılır (Shorten & Khoshgoftaar, 2019).

Kırpma (Random Crop): Görsellerin belirli kısımları rastgele seçilerek öğrenmenin lokal örneklere dayanması sağlanır.

Gaussian Gürültü: Az miktarda rastgele gürültü ile modelin daha sağlam hale gelmesi hedeflenir (Taylor & Nitschke, 2018).

Bu işlemler, eğitim seti çeşitliliğini artırarak modelin sadece eğitim örneklerine ezber yapmasını engeller; dolayısıyla test seti üzerindeki doğruluğu artırır ve genelleme yeteneğini güçlendirir (Monshi et al., 2021).

E. Deney Ortamı

Tüm deneyler, Intel i7 CPU, 16GB RAM ve NVIDIA GTX 1660 GPU donanımına sahip bir sistem üzerinde gerçekleştirilmiştir. Eğitim süreci ortalama 4 dakika sürmüştür; doğruluk ve kayıp metrikleri her epoch sonunda kaydedilmiştir.

IV. SONUÇ

Bu çalışmada, veri artırma tekniklerinin CNN tabanlı görüntü sınıflandırma modellerinin performansı üzerindeki etkileri incelenmiştir. CIFAR-10 veri seti üzerinde gerçekleştirilen deneyler, veri artırmanın modelin doğruluk oranlarını artırdığını ve doğrulama kayıplarını azalttığını açıkça göstermiştir. Veri

artırma yöntemleri sayesinde modelin aşırı öğrenme (overfitting) eğilimi azalmış, daha iyi bir genelleme kapasitesi elde edilmiştir.

Eğitim süreci boyunca kaydedilen kayıp ve doğruluk değerleri, veri artırmanın modelin eğitim verisinden daha etkili öğrenmesini sağladığını ve test verisi üzerinde daha yüksek performans sergilediğini kanıtlamıştır. Özellikle, doğrulama doğruluğunda gözlemlenen %12'lik artış, veri artırma stratejilerinin küçük ve orta ölçekli veri setleri için ne kadar kritik bir rol oynadığını göstermektedir.

Gelecek çalışmalarda, daha ileri düzey veri artırma yöntemlerinin (örneğin CutMix, MixUp, GAN tabanlı augmentasyon) etkisi araştırılabilir. Ayrıca, farklı CNN mimarileri (örneğin ResNet, DenseNet gibi daha derin yapılar) kullanılarak daha büyük ve daha karmaşık veri setleri üzerinde testler yapılması önerilmektedir. Bu tür çalışmalar, veri artırma tekniklerinin derin öğrenme modelleri üzerindeki genel etkisini daha kapsamlı şekilde ortaya koyacaktır.

V. TARTIŞMA

Bu çalışmada, CNN tabanlı bir görüntü sınıflandırma modeline veri artırma tekniklerinin etkisi kapsamlı şekilde incelenmiştir. Sonuçlar, veri artırma uygulanan modellerin doğruluk oranlarında ve doğrulama kaybı değerlerinde belirgin iyileşmeler sağladığını göstermektedir.

Veri artırmanın model performansına katkısı, özellikle eğitim veri setinin sınırlı olduğu durumlarda belirginleşmektedir (Shorten & Khoshgoftaar, 2019). Bu çalışmada da gözlemlendiği üzere, basit dönüşüm teknikleri (örneğin yatay çevirme, rastgele kırpma, döndürme) ile modelin eğitim sürecinde çeşitlilik artırılmış, aşırı öğrenme (overfitting) riski azaltılmış ve modelin genelleme kapasitesi geliştirilmiştir (Aquino et al., 2017).

Elde edilen sonuçlar literatürde yer alan diğer çalışmaları destekler niteliktedir. Örneğin, Bjerrum ve arkadaşlarının (Bjerrum et al., 2017) spektral veriler üzerinde yaptıkları çalışmada da veri artırmanın model performansını iyileştirdiği rapor edilmiştir. Benzer şekilde Monshi ve arkadaşları (Monshi et al., 2021), Covid-19 görüntülerinin sınıflandırılması için veri artırmanın kritik bir rol oynadığını vurgulamışlardır.

Bu çalışmanın sınırlılığı, sadece temel veri artırma tekniklerinin kullanılması ve CIFAR-10 gibi görece basit bir veri seti üzerinde değerlendirme yapılmasıdır. Daha karmaşık veri artırma yöntemlerinin (örneğin CutMix, MixUp, GAN-tabanlı artırma) ve farklı CNN mimarilerinin etkisi ileriki çalışmalarda incelenebilir.

KAYNAKLAR

- Taylor, L., & Nitschke, G. (2018). Improving deep learning with generic data augmentation. *2018 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://doi.org/10.1109/IJCNN.2018.8489608>
- Claro, A., Monge, D. A., & Rios, S. A. (2022). Data augmentation for medical image classification using deep learning. *Biomedical Signal Processing and Control*, 71, 103715. <https://doi.org/10.1016/j.bspc.2022.103715>
- Bjerrum, E. J., & Glahder, M. A. (2017). Data augmentation of spectral data for convolutional neural networks. *arXiv preprint arXiv:1710.01927*, <https://arxiv.org/abs/1710.01927>
- Monshi, M. M., Poon, J., & Chung, V. (2021). CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19 chest X-ray classification. *Computers in Biology and Medicine*, 133, 104457. <https://doi.org/10.1016/j.compbiomed.2021.104457>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <https://www.deeplearningbook.org>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929–1958. <http://jmlr.org/papers/v15/srivastava14a.html>
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, <https://arxiv.org/abs/1412.6980>