

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 –

Anahtar Kelimeler – Veri Artırma, CNN, Derin Sinir Ağları.

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 artırmalı 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 Artırmalı ve Artırmaz Eğitim Senaryolarında CNN Model Performans Karşılaştırması

Metrik	Veri Artırmaz	Veri Artırmalı
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 Artırmalı CNN Modelinin Test Doğruluğu (%)



Şekil 2. Veri Artırmalı 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.

```

class SimpleCNN(nn.Module):
    def __init__(self):
        super(SimpleCNN, self).__init__()
        self.conv1 = nn.Conv2d(3, 32, kernel_size=3, padding=1)
        self.conv2 = nn.Conv2d(32, 64, kernel_size=3, padding=1)
        self.pool = nn.MaxPool2d(2, 2)
        self.fc1 = nn.Linear(64 * 8 * 8, 512)
        self.fc2 = nn.Linear(512, 10)
        self.dropout = nn.Dropout(0.25)

    def forward(self, x):
        x = self.pool(F.relu(self.conv1(x)))
        x = self.pool(F.relu(self.conv2(x)))
        x = x.view(-1, 64 * 8 * 8)
        x = self.dropout(F.relu(self.fc1(x)))
        return self.fc2(x)

```

Şekil 3

C. Eğitim Parametreleri

Çalışmada kullanılan Convolutional Neural Network (CNN) modeli, giriş verilerindeki temel ve karmaşık özellikleri aşamalı olarak çıkarabilmek için iki konvolüsyon katmanı ve bir tam bağlı katman yapısına sahiptir. Model mimarisi aşağıda verilmiştir:

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.

KAYNAKLAR

- [1] Yakar, M., Yılmaz, H. M., & Mutluoglu, O. (2014). Performance of photogrammetric and terrestrial laser scanning methods in volume computing of excavation and filling areas. *Arabian Journal for Science and Engineering*, 39, 387-394.
- [2] Alptekin, A., & Yakar, M. (2020). Determination of pond volume with using an unmanned aerial vehicle. *Mersin Photogrammetry Journal*, 2(2), 59-63.
- [3] Karataş, L., Alptekin, A., & Yakar, M. (2022). Mardin historical Kuyumcular (Jewelers) Bazaar restoration evaluation. *Advanced Engineering Days (AED)*, 5, 15-17.
- [4] Maune, D. F. (2001). Digital elevation model technologies and applications: The DEM user manual. The American Society for Photogrammetry and Remote Sensing. ISBN:1-57083-064-9