

Geleneksel Görüntü İşleme ve Derin Öğrenmenin Birleşimi Hibrid Model ile El Yazısı Rakam Sınıflandırma

Ethem Sefa KÜÇÜKYILMAZ^{1,a}, Erhan AKIN^{2,b}

¹Fırat Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim ve Bilişim Sistemleri Bölümü, Elazığ, Türkiye

²Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye

^aORCID: 0009-0008-6912-1851; ^bORCID: 0000-0001-6476-9255

Makale Bilgileri

Geliş : 07.04.2025

Kabul : 06.02.2026

DOI: 10.21605/cukurovaumfd.1670508

Sorumlu Yazar

Ethem Sefa KÜÇÜKYILMAZ

eskucukyilmaz@firat.edu.tr

Anahtar Kelimeler

Hibrit model

El yazısı rakam sınıflandırması

Görüntü işleme teknikleri

Optik karakter tanıma (OCR)

Öznitelik çıkarımı

Atf şekli: KÜÇÜKYILMAZ, E.S., AKIN, E., (2026). Geleneksel Görüntü İşleme ve Derin Öğrenmenin Birleşimi Hibrid Model ile El Yazısı Rakam Sınıflandırma. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 41(1), 145-154.

ÖZ

Bu çalışma, rakam sınıflandırma problemlerinde yaygın olarak kullanılan Konvolüsyonel Sinir Ağları'nın (CNN) dönme ve ölçekleme gibi geometrik varyasyonlara karşı yaşadığı yetersizlikleri gidermek amacıyla hibrit bir model önermektedir. Önerilen yaklaşım, CNN mimarisini Hu ve Zernike Momentlerinin sağladığı geometrik değişmezlik özellikleriyle entegre ederek özellik birleştirme tekniğini kullanmaktadır. Modelin dayanıklılığı, standart veriler yerine gürültü ve bozulma içeren zorlu SVHN veri seti üzerinde test edilmiştir. Çalışma kapsamında modern ve hafif bir mimari olan MobileNetV3 ile yapılan kapsamlı kıyaslamalar, hibrit modelin %90.97 ile istatistiksel olarak rekabetçi bir doğruluk oranına ulaştığını göstermiştir. Ancak asıl fark işlem hızında ortaya çıkmış; hibrit model 760 ms işlem süresiyle, 3276 ms süren MobileNetV3 modeline kıyasla 4 kattan fazla hız avantajı sağlamıştır. Bu sonuçlar, önerilen yöntemin yüksek doğruluk ve hız gerektiren gerçek zamanlı uygulamalar için modern alternatiflerden çok daha verimli bir çözüm sunduğunu kanıtlamaktadır.

Handwritten Digit Classification with a Hybrid Model Combining Traditional Image Processing and Deep Learning

Article Info

Received : 07.04.2025

Accepted : 06.02.2026

DOI: 10.21605/cukurovaumfd.1670508

Corresponding Author

Ethem Sefa KÜÇÜKYILMAZ

eskucukyilmaz@firat.edu.tr

Keywords

Hibrit model

Handwritten digit classification

Image processing techniques

Optical character recognition (OCR)

Feature extraction

How to cite: KÜÇÜKYILMAZ, E.S., AKIN, E., (2026). Handwritten Digit Classification with a Hybrid Model Combining Traditional Image Processing and Deep Learning. Çukurova University, Journal of the Faculty of Engineering, 41(1), 145-154.

ABSTRACT

This study proposes a hybrid model to address the insufficiencies of Convolutional Neural Networks (CNNs), widely used in digit classification, against geometric variations such as rotation and scaling. The proposed approach integrates CNN architecture with the geometric invariance properties of Hu and Zernike Moments using a feature fusion technique. To test robustness, the model was evaluated on the challenging SVHN dataset, containing noise and real-world distortions, rather than standard datasets. Comprehensive comparisons with MobileNetV3, a modern lightweight architecture, showed that the hybrid model achieved a statistically competitive accuracy rate of 90.97%. However, the significant difference appeared in processing speed; the hybrid model demonstrated more than a 4-fold speed advantage (760 ms) compared to MobileNetV3 (3276 ms). These findings prove that the proposed method offers a significantly more efficient solution than modern alternatives for real-time applications requiring high accuracy and low computational cost.

1. GİRİŞ

Görüntü tanıma, bilgisayarlı görü ve makine öğrenmesi alanlarında uzun yıllardır üzerinde çalışılan temel problemlerden biridir [1]. Nesne tanıma, yüz algılama, tıbbi görüntü analizi ve otonom araçlar gibi pek çok uygulama, gelişmiş görüntü sınıflandırma tekniklerine dayanmaktadır. Bu bağlamda, el yazısı rakamların sınıflandırılması, Optik Karakter Tanıma (OCR) sistemlerinin en kritik alt bileşenlerinden birini oluşturmaktadır [2]. Ancak bu noktada, tam kapsamlı bir OCR sisteminin metin tespiti (text detection) ve satır ayrıştırma gibi adımları içerdiği; bu çalışmanın ise doğrudan önceden ayrıştırılmış (pre-segmented) izole karakterlerin sınıflandırılması problemi üzerine odaklandığı vurgulanmalıdır.

Makine öğrenmesi ve derin öğrenme alanındaki gelişmeler, izole karakterlerin sınıflandırılmasında yüksek doğruluk oranlarına ulaşmayı mümkün kılmıştır. Geleneksel makine öğrenmesi yöntemleri, öznitelik mühendisliği ve istatistiksel analizlere dayalı teknikler kullanırken; günümüzde Konvolüsyonel Sinir Ağları (CNN) gibi derin öğrenme yöntemleri, doğrudan görüntü pikselleri üzerinden anlamlı özellikler öğrenerek başarılı sonuçlar vermektedir [3]. Özellikle LeCun ve arkadaşları tarafından sunulan MNIST veri kümesi [4], bu alandaki algoritmaların kıyaslanması için standart bir referans noktası kabul edilmektedir. Zamanla bu alandaki modeller giderek derinleşmiş ve ResNet gibi mimarilerde kullanılan atlamalı bağlantılar sayesinde derin ağların eğitiminde karşılaşılan kaybolan gradyan problemleri etkin bir şekilde çözülmüştür [5]. Buna ek olarak, model mimarilerindeki aktivasyon fonksiyonlarının (örneğin düzeltilmiş sigmoid) optimize edilmesiyle de standart veri setlerindeki sınıflandırma performansları daha da yukarı taşınmıştır [6]. CNN tabanlı yaklaşımlar büyük veri kümelerinde yüksek performans gösterse de, yapısal veya geometrik değişmezlik (invariance) bilgilerini modele açıkça dahil etmek, özellikle sınırlı veri veya karmaşık varyasyonlarda performansı artırabilmektedir. Bu çalışmada, CNN modellerinin veri odaklı gücü ile Hu Momentleri [7] gibi geleneksel yöntemlerin geometrik değişmezlik özellikleri bir araya getirilerek hibrit bir mimari sunulmuştur.

Hu Momentleri, bir görüntünün geometrik dönüşümlere (ölçekleme, döndürme ve öteleme) karşı dayanıklı özelliklerini tanımlayan istatistiksel ölçümlerden oluşur. Bu momentler, bir şeklin temel yapısını özetleyen yedi adet değişmez değer üretir ve özellikle karakter ve şekil tanıma uygulamalarında yaygın olarak kullanılmaktadır. Bunun yanı sıra, Zernike Momentleri daha yüksek doğrulukta şekil analizine olanak tanıyan ve görüntü üzerindeki farklı frekans bileşenlerini temsil eden özel momentlerdir. Zernike Momentleri, ortogonal bir taban fonksiyonuna dayalı olarak hesaplandığı için, görüntünün bütünsel yapısını daha iyi yakalayarak modelin farklı varyasyonlara karşı dayanıklılığını artırmaktadır.

Önerilen yöntemde, ilk olarak MNIST veri kümesi kullanılarak el yazısı rakamları üzerinde deneyler gerçekleştirilmiştir. MNIST veri kümesi, 28x28 boyutlarında el yazısı rakam görüntülerinden oluşan geniş bir veri kümesi olup, görüntü sınıflandırma algoritmalarının test edilmesi için standart bir benchmark olarak kabul edilmektedir. Çalışmada, CNN modeli ve geleneksel moment tabanlı özelliklerin birleştirilerek kullanılmasıyla daha güçlü bir sınıflandırma performansı elde edilmiştir.

Modelin geliştirilmesi aşamasında, CNN bileşeni için bir dizi konvolüsyonel katman ve havuzlama katmanı kullanılarak görüntülerden anlamlı özellikler çıkarılmıştır. Bu özellikler, tam bağlı katmanlara iletilerek rakam sınıflandırması gerçekleştirilmiştir. Geleneksel öznitelik mühendisliği aşamasında ise, her bir görüntü için Hu ve Zernike Momentleri hesaplanarak CNN modeline eklenmiştir. Modelin son aşamasında, CNN tarafından çıkarılan özellikler ile geleneksel yöntemlerden elde edilen öznitelikler birleştirilerek son sınıflandırma işlemi gerçekleştirilmiştir.

Bunun yanı sıra, modelin eğitim sürecinde Cosine Annealing Learning Rate Scheduler kullanılarak adaptif öğrenme oranı ayarlamaları gerçekleştirilmiştir. Öğrenme sürecinin daha stabil ilerlemesini sağlamak için Early Stopping tekniği kullanılmış, ayrıca modelin aşırı öğrenmesini (overfitting) önlemek için Dropout katmanları eklenmiştir. Ayrıca, veri kümesini zenginleştirmek amacıyla ImageDataGenerator ile veri artırma işlemleri uygulanmış, böylece modelin daha geniş varyasyonlara karşı dayanıklı hale gelmesi sağlanmıştır ve çalışmanın sunduğu temel katkılar şu şekilde özetlenebilir:

- Hibrit Model Kullanımı: Derin öğrenme ve geleneksel öznitelik mühendisliği tekniklerinin birleştirilerek daha güçlü bir model oluşturulması sağlanmıştır.

- Görüntü Özniteliklerinin Entegrasyonu: Hu Momentleri ve Zernike Momentleri gibi yapısal bilgilerin CNN modeline entegre edilerek sınıflandırma performansının artırılması hedeflenmiştir.
- Öğrenme Oranı Optimizasyonu: Cosine Annealing Learning Rate Scheduler ile modelin öğrenme sürecinin daha dengeli ilerlemesi sağlanmıştır.
- Veri Artırma Stratejilerinin Kullanımı: ImageDataGenerator ile uygulanan veri artırma teknikleri sayesinde modelin genelleme yeteneği artırılmıştır.
- Model Performansının Değerlendirilmesi: CNN modelinin yalnızca piksel tabanlı öğrenme yerine, ek özniteliklerle desteklendiğinde nasıl daha başarılı sonuçlar verdiği gösterilmiştir.

Sonuç olarak, bu çalışmada, derin öğrenme ve geleneksel görüntü işleme tekniklerinin hibrit bir yapı içinde nasıl entegre edilebileceği gösterilmiştir. Elde edilen bulgular, CNN modellerinin geleneksel öznitelik mühendisliği yöntemleriyle desteklenerek daha yüksek performans elde edebileceğini göstermektedir. Bu yaklaşım, el yazısı rakam sınıflandırmasının yanı sıra, diğer görüntü sınıflandırma problemlerinde de uygulanabilecek potansiyel bir yöntem olarak değerlendirilebilir.

2. LİTERATÜR TARAMASI

Görüntü sınıflandırma problemleri, makine öğrenmesi ve derin öğrenme alanında geniş bir araştırma sahası oluşturmakta olup, özellikle Konvolüsyonel Sinir Ağları (CNN) ve moment tabanlı özellik çıkarım yöntemleri gibi yaklaşımlar bu alanda önemli bir yer tutmaktadır. Görüntü işleme ve sınıflandırma alanında karşılaşılan zorluklar, modellerin doğruluk, hız ve genelleme yeteneğini artırmak için çeşitli yöntemlerin geliştirilmesini zorunlu kılmıştır. Bu bağlamda, CNN modelleri ve moment tabanlı teknikler, görüntüden anlamlı özelliklerin çıkarılması ve bu özellikler üzerinden yüksek doğrulukla sınıflandırma yapılmasında kritik rol oynamaktadır. Bu yöntemler, görüntü işleme alanında hem teorik hem de pratik açıdan büyük bir öneme sahiptir ve sürekli olarak geliştirilmektedir. CNN modelleri, özellikle görüntü tanıma ve sınıflandırma problemlerinde sağladıkları yüksek doğruluk oranları ve otomatik özellik çıkarım kabiliyetleri nedeniyle popüler hale gelmiştir [1]. Bu mimari, görüntüdeki lokal özellikleri yakalamada ve bu özellikleri daha yüksek seviyeli temsillere dönüştürmede son derece etkilidir. Özellikle MNIST veri kümesi gibi el yazısı rakam sınıflandırma problemlerinde CNN tabanlı modellerin doğruluk oranlarının %97'yi aştığı gösterilmiştir [2]. CNN'in temel bileşenleri olan evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlar sayesinde, giriş görüntüsünden soyut ve anlamlı temsiller öğrenmek mümkün olmaktadır [3]. Bu mimarilerin temellerini atan ve belge tanıma sistemlerine gradyan tabanlı öğrenmeyi başarıyla uygulayan LeCun ve arkadaşlarının çalışmaları, el yazısı rakam sınıflandırması alanının en önemli yapı taşlarından birini oluşturmaktadır [4]. Farklı CNN mimarileri arasında LeNet, AlexNet, VGG, ResNet gibi modeller, derin katman yapıları ve farklı evrişim teknikleri ile öne çıkmaktadır. Örneğin, ResNet'in sunduğu atlamalı bağlantılar, derin ağların eğitiminde karşılaşılan kaybolan gradyan problemini etkili bir şekilde çözmektedir [5]. Ayrıca farklı aktivasyon fonksiyonlarının model başarısına doğrudan etki ettiği, düzeltilmiş sigmoid fonksiyonunun MNIST veri setinde %89,82 doğruluk sağladığı belirtilmektedir [6]. Bu sonuçlar, CNN modellerinin görüntü sınıflandırma problemlerinde ne kadar etkili olduğunu göstermektedir. Moment tabanlı özellik çıkarım yöntemleri, görüntülerin geometrik dönüşümlere (ölçekleme, döndürme, öteleme) karşı değişmezliğini sağlayan istatistiksel öznitelikler sunar. Bu yöntemler, görüntünün şekil, boyut ve oryantasyon gibi temel özelliklerini matematiksel olarak temsil ederek, sınıflandırma algoritmalarının bu özellikler üzerinden karar vermesini kolaylaştırır. Hu Momentleri, bu dönüşümler altında görüntünün temel yapısını koruyan öznitelikler çıkararak, özellikle dönüşüm değişmezliği gerektiren tanıma problemlerinde etkin bir şekilde kullanılmaktadır [7]. Singh ve arkadaşları, Hu momentlerinin dijital görüntülerde ayrıklaştırma nedeniyle bazı bozulmalar yaşayabileceğini, ancak yine de tanıma açısından sağlam bir yöntem sunduğunu ifade etmektedir [8]. Bu momentler, yedi adet değişmez özellikten oluşmakta olup, bu özellikler farklı geometrik dönüşümlere karşı kararlılık sağlamaktadır. Hu Momentleri, özellikle tıbbi görüntüleme ve nesne tanıma gibi alanlarda yaygın olarak kullanılmaktadır. Zernike Momentleri ise görüntülerin dairesel harmonik fonksiyonlar kullanılarak ayrıştırılmasını sağlar ve döndürmeye karşı değişmezlik özellikleri nedeniyle öne çıkar [9]. Bu momentler, düşük örnekleme oranlarında görüntü rekonstrüksiyonunu kolaylaştırırken, arka plan gürültüsüne karşı da daha dayanıklı oldukları gösterilmiştir [10]. Zernike Momentlerinin karmaşık sayı yapısı, görüntünün daha zengin ve anlamlı bir şekilde temsil edilmesini sağlar. Özellikle yüksek dereceli momentler, görüntüdeki detayların daha iyi yakalanmasına olanak tanır. Zheng ve arkadaşları, kesirli mertebeden Zernike

momentlerinin filigranlama gibi güvenlik uygulamalarında başarıyla kullanıldığını göstermiştir [11]. Benzer şekilde, görüntü güvenliğinin kritik olduğu durumlarda, çoklu örtü görüntüleri ve algısal özetleme (perceptual hash) teknikleri kullanılarak geliştirilen veri gizleme yöntemleri de literatürde önemli bir yer tutmaktadır [12]. Bu tür momentler, görüntü işleme alanında hem teorik hem de pratik açıdan büyük bir öneme sahiptir ve sürekli olarak geliştirilmektedir.

Son yıllarda, geleneksel özellik mühendisliği teknikleri ile derin öğrenme tabanlı yaklaşımların birleştirildiği hibrit modeller, görüntü sınıflandırma problemlerinde giderek artan bir popülerlik kazanmaktadır. Bu tür modeller, CNN gibi derin öğrenme tabanlı yöntemlerin güçlü yönlerini, moment tabanlı özellik çıkarma yöntemleriyle destekleyerek daha yüksek doğruluk oranları elde etmeyi amaçlar. Hu ve Zernike momentlerini kullanan bir dış çürüğü sınıflandırma modelinde, KNN algoritması ile %94,07 doğruluk oranına ulaşıldığı gösterilmiştir [13]. Bu sonuçlar, moment tabanlı özelliklerin makine öğrenmesi algoritmalarıyla birleştirildiğinde oldukça başarılı çıktılar verdiğini göstermektedir. Hibrit modeller, özellikle tıbbi görüntüleme ve nesne tanıma gibi alanlarda büyük bir potansiyele sahiptir. MNIST veri kümesi, el yazısı rakam sınıflandırma problemlerinde en sık kullanılan veri setlerinden biridir. Daha hafif CNN modelleri ile bile oldukça yüksek doğruluk oranlarına ulaşabilmektedir; örneğin LMFRNet adlı bir model, MNIST üzerinde %94,6 doğruluk oranına ulaşmıştır [14]. Bu teknikler, aşırı uyumu (overfitting) azaltarak modelin farklı veri örnekleri üzerinde daha iyi genelleme yapmasını sağlar. Veri artırma teknikleri, özellikle sınırlı veri setleri üzerinde çalışırken büyük bir avantaj sağlamaktadır. Bu tür hibrit modeller, özellikle endüstriyel uygulamalarda büyük bir potansiyele sahiptir. Nitekim makine öğrenmesi modelleri, sadece görüntü işlemede değil, ısı değiştirici tasarımı gibi endüstriyel sistemlerin optimizasyonunda da ağaç tabanlı algoritmalarla (XGBoost, RF vb.) yüksek başarı sağlamaktadır [15].

3. YÖNTEM

3.1. Kullanılan Veri Kümesi

Bu çalışmada, önerilen hibrit modelin hem temel öğrenme kapasitesini hem de zorlu koşullardaki dayanıklılığını değerlendirmek amacıyla iki farklı veri seti kullanılmıştır. İlk olarak, modelin temel başarımını ölçmek için standart bir referans noktası olan MNIST veri seti tercih edilmiştir. MNIST, 0-9 arası rakamları içeren, 28x28 boyutunda ve gri tonlamalı 70.000 görüntüden oluşmaktadır. Ancak, MNIST veri setinin temiz ve hizalanmış yapısı, modelin gerçek dünya senaryolarındaki gürültüye karşı direncini ölçmekte yetersiz kalabilmektedir. Bu nedenle, çalışmanın kapsamı genişletilerek modele SVHN (Street View House Numbers) veri seti dahil edilmiştir. SVHN, Google Street View görüntülerinden elde edilen, gerçek dünya kapı numaralarını içeren ve MNIST'e kıyasla çok daha zorlu bir veri setidir. 32x32 piksel boyutunda ve RGB (renkli) formatında olan bu veri seti, değişken aydınlatma koşulları, bulanıklık, geometrik bozulmalar ve arka plan gürültüleri içermektedir. SVHN, modelin yalnızca şekil bilgisini değil, aynı zamanda gürültülü ve karmaşık arka planlara karşı geometrik değişmezlik (Hu ve Zernike momentleri sayesinde) yeteneğini test etmek için ideal bir ortam sunmaktadır.

3.2. Geleneksel Özellik Çıkartma Yöntemleri

Görüntü tanıma ve sınıflandırma problemlerinde, görüntülerin ham piksel değerlerinden doğrudan öğrenmek yerine, bu görüntülerden anlamlı ve dönüşüm değişmez özellikler çıkartmak yaygın bir yaklaşımdır. Bu bağlamda Hu Momentleri ve Zernike Momentleri, geleneksel özellik çıkarma yöntemleri arasında önemli bir yere sahiptir. Bu çalışmada, MNIST veri kümesi üzerinde Hu Momentleri ve Zernike Momentleri birleştirilerek, log-normalizasyon işlemiyle iyileştirilen özellikler çıkarılmış ve bir CNN modeline ek girdi olarak sunulmuştur.

Hu Momentleri, bir görüntünün geometrik yapısını özetleyen yedi adet momentten oluşur ve döndürme, ölçekleme ve öteleme gibi dönüşümlere karşı değişmezdir. Bu özellikleri nedeniyle görüntü tanıma ve karakter sınıflandırma gibi alanlarda sıkça kullanılmaktadır. Hu Momentleri, normalize edilmiş merkezi momentlerin doğrusal olmayan kombinasyonlarıdır ve şu formüllerle tanımlanır:

$$n_1 = m_{20} + m_{02} \quad (1)$$

$$n_2 = (m_{20} - m_{02})^2 + 4m_{11}^2 \quad (2)$$

$$n_3 = (m_{30} - 3m_{12})^2 + (3m_{21} - m_{03})^2 \quad (3)$$

$$n_4 = (m_{20}m_{02} - m_{11}^2)^2 + (m_{30}m_{03} - 3m_{12}m_{21})^2 \quad (4)$$

$$n_5 = (m_{20} + m_{02})^2 + 4m_{11}^2 \quad (5)$$

$$n_6 = (m_{30} + m_{12})^2 + (m_{21} + m_{03})^2 \quad (6)$$

$$n_7 = (m_{20}m_{02} - m_{11}^2)^2 + (m_{30}m_{03} - 3m_{12}m_{21})^2 \quad (7)$$

Bu momentler, görüntülerin temel yapısal özelliklerini tanımlamak için idealdir. Ancak Hu Momentlerinin büyüklükleri arasında ciddi farklılıklar olabileceği için, modelin bu değerleri dengeli bir şekilde işlemesi zorlaşabilir. Bu sorunu çözmek amacıyla log-normalizasyon uygulanır:

$$\emptyset_i^* = -sgn(\emptyset_i) \cdot \log_{10}(|\emptyset_i| + 1e - 10) \quad (8)$$

Buradaki sgn fonksiyonu, momentin işaretini korurken logaritmik dönüşüm, değerleri ölçek bağımsız hale getirir. Bu sayede özellik vektöründeki tüm momentler daha dengeli bir dağılıma kavuşur. Çalışmamızda, MNIST veri kümesindeki her bir görüntü için Hu Momentleri hesaplanmış, ardından yukarıda tanımlanan log-normalizasyon işlemi uygulanmıştır.

Zernike Momentleri, döndürme değişmezliği sağlayan ve bir görüntünün şekil özelliklerini dairesel harmonik fonksiyonlar kullanarak temsil eden ortogonal momentlerdir. Bu momentler, bir görüntünün frekans tabanlı temsiline benzer şekilde çalışarak, karmaşık yapıları daha etkin bir şekilde modelleme yeteneği sunar ve aşağıdaki denklemde olduğu gibi tanımlanır:

$$Z_{nm} = \frac{n+1}{n} \sum_x \sum_y f(x, y) V_{nm}^*(x, y) \quad (9)$$

Burada V_{nm}^* Zernike polinomlarını temsil ederken $f(x, y)$ ise görüntü piksel değerlerini temsil ediyor. Bu çalışmada, MNIST görüntülerinden Zernike Momentleri çıkarılmıştır. Zernike Momentlerinin ilk 8 bileşeni, Hu Momentleri ile birleştirilerek nihai özellik vektörü oluşturulmuştur.

Hu Momentleri ve Zernike Momentleri birleştirilerek 15 boyutlu bir özellik vektörü oluşturulmuştur. Bu özellikler, Evrişimli Sinir Ağı (CNN) modeline ek bir giriş olarak sunulmuştur. Elde edilen bu 15 boyutlu vektörler, CNN modeline ikinci bir giriş olarak eklenmiş ve modelin performansı belirgin şekilde iyileştirilmiştir. Özellikle log-normalize edilmiş Hu Momentlerinin ve ilk 8 Zernike Momentinin birleşimi, modelin hem doğruluk oranını artırmış hem de dönüşüm değişmez özellikler sayesinde modelin genelleme yeteneğini güçlendirmiştir.

Sonuç olarak, geleneksel özellik çıkarma yöntemlerinin derin öğrenme modellerine entegre edilmesi, modelin performansını iyileştirmede etkili olmuştur. Hu ve Zernike Momentlerinin sunduğu dönüşüm değişmez özellikler, modelin farklı varyasyonlardaki verilerle daha başarılı tahminler yapmasını sağlamıştır.

3.3. Önerilen Hibrid Model

Önerilen hibrit modelde, CNN mimarisi görsel özelliklerin çıkarılmasında ana yapı taşını oluşturmaktadır. SVHN veri kümesi üzerinde çalışıldığı için modelin girdi verisi 32x32 boyutunda üç kanallı (RGB) görüntülerdir. CNN yapısında, özellik çıkarımını güçlendirmek amacıyla ardışık konvolüsyon blokları kullanılmıştır. İlk blokta 32 filtrelili, ikinci blokta 64 filtrelili ve üçüncü blokta 128 filtrelili 3x3 boyutunda evrişim katmanları yer almaktadır. Her evrişim katmanının ardından, öğrenme sürecini hızlandırmak ve kararlılığı artırmak için Batch Normalization uygulanmış ve özellik haritalarının boyutunu küçültmek için 2x2 boyutunda Maksimum Havuzlama (Max Pooling) katmanları eklenmiştir. Havuzlama işlemlerinin ardından elde edilen özellik haritaları düzleştirilerek (Flatten) tek boyutlu vektör haline getirilmiş ve 256 nöronlu tam bağlantılı (dense) bir katmana iletilmiştir. Bu katmanda ReLU aktivasyon fonksiyonu kullanılmış ve modelin aşırı öğrenmesini (overfitting) engellemek amacıyla %50 oranında Dropout uygulanmıştır. İlgili model parametrelerinin detaylıca gösterimi Çizelge 1 de olduğu gibidir.

Çizelge 1. Hibrit modelin parametreleri

Katman adı	Girdi boyutu	Çıkış boyutu	Açıklama
cnn_input	(32, 32, 3)	(32, 32, 3)	SVHN görüntüleri (32x32 RGB)
Conv2D + Batch	(32, 32, 3)	(32, 32, 32)	32 filtreli evrişim ve normalizasyon
MaxPooling2D	(32, 32, 32)	(16, 16, 32)	Boyut azaltma
Conv2D + Batch	(16, 16, 32)	(16, 16, 64)	64 filtreli evrişim (derinleşme)
MaxPooling2D	(16, 16, 64)	(8, 8, 64)	Boyut azaltma
Flatten	(8, 8, 64)	(4096,)	Düzleştirme işlemi
Dense	(4096,)	(256,)	Derin öznetelik çıkarımı
Dropout	(256,)	(256,)	%50 Dropout (Aşırı öğrenme önlemi)
moment_input	(15,)	(15,)	Hu ve Zernike momentleri
Dense + Batch	(15,)	(64,)	Momentlerin işlenmesi
Concatenate	(256,) + (64,)	(320,)	Özellik birleştirme (Fusion)

Geleneksel özellik çıkarma sürecinde, Hu Momentleri ve Zernike Momentlerinden yararlanılmıştır. Hu Momentleri, görüntünün şekil bilgilerini dönüşüm değişmez bir şekilde tanımlayan yedi farklı katsayıdan oluşmaktadır. Bu çalışmada Hu Momentlerine log-normalizasyon uygulanarak, moment değerlerindeki ölçek farklarının giderilmesi sağlanmış ve sayısal kararlılık artırılmıştır. Zernike Momentleri ise, görüntünün dairesel harmonik fonksiyonlar cinsinden temsiline dayanarak, dönme değişmez ve daha ayrıntılı bir özellik kümesi sunmaktadır. Bu bağlamda, Zernike Momentlerinin ilk sekiz terimi modele dahil edilmiştir. Hu ve Zernike Momentlerinden elde edilen toplam 15 boyutlu özellik vektörü, modelin ikinci girdi katmanı olarak tanımlanmıştır. Önerilen modelin bir diğer önemli unsuru, CNN ve geleneksel özelliklerin birleştirilmesi sürecidir. CNN'in çıkardığı derin özellikler ile Hu ve Zernike Momentlerinden elde edilen geleneksel özellikler birleştirilmiş ve bu birleşik özellik uzayı üzerinden nihai sınıflandırma yapılmıştır. İki farklı özellik kümesi bir araya getirilirken, geleneksel özelliklerin boyutu 16 nöronlu bir tam bağlantılı katman aracılığıyla modellenmiş ve böylece CNN katmanlarıyla uyum sağlanmıştır. Birleştirilen özelliklerden elde edilen bu zengin temsil, 32 nöronlu bir ara katman aracılığıyla işlenmiş ve softmax aktivasyon fonksiyonuna sahip bir çıkış katmanı ile 10 sınıflı MNIST rakamlarının tahmini gerçekleştirilmiştir. Modelin optimizasyon sürecinde Adam algoritması kullanılmıştır. Adam optimizatörü, adaptif öğrenme oranı yaklaşımı ile parametre güncellemelerini hızlandırırken, modelin kararlılığını da artırmaktadır. Kaybı ölçmek için kategorik çapraz entropi fonksiyonu tercih edilmiştir. Modelin performansını daha da artırmak için öğrenme oranının dinamik olarak ayarlanmasına olanak tanıyan Cosine Annealing Learning Rate Scheduler uygulanmıştır. Cosine Annealing, epoch sayısına bağlı olarak öğrenme oranını kosinüs fonksiyonuna göre düzenleyerek, optimizasyon sürecinin daha dengeli ve verimli ilerlemesini sağlamaktadır. Minimum ve maksimum öğrenme oranı arasında dalgalanan bu yöntem, modelin lokal minimumlara takılmadan daha geniş bir parametre alanını keşfetmesine yardımcı olmuştur. Model eğitimi sırasında aşırı öğrenmenin önüne geçmek ve modelin doğrulama setindeki performansını korumak amacıyla çeşitli erken durdurma ve öğrenme oranı ayarlama stratejileri uygulanmıştır. Early Stopping (Erken Durdurma) tekniği, doğrulama kaybında belirli bir iyileşme gözlenmediğinde eğitim sürecini sonlandırarak modelin gereksiz yere aşırı uyum sağlamasını engellemiştir. Önerilen hibrit modelin eğitimi, 50 epoch boyunca ve 512'lik batch size ile gerçekleştirilmiştir. Eğitim sürecinde modelin hem eğitim hem de doğrulama setindeki kayıp ve doğruluk değerleri takip edilmiştir. Eğitim sonunda modelin başarı performansını doğruluk, precision, recall, F1-score gibi metriklerle değerlendirilmiş ve elde edilen sonuçlar gözlemlenmiştir. Ayrıca, tahmin edilen ve gerçek sınıflar arasındaki ilişkileri daha iyi analiz edebilmek için karışıklık matrisi oluşturulmuş ve modelin hangi sınıflarda ne derece başarılı olduğu detaylı bir şekilde incelenmiştir. Önerilen hibrit modelin performansı, yalnızca CNN mimarisine dayalı modellerle kıyaslandığında belirgin bir iyileşme göstermiştir. Hu ve Zernike Momentlerinden elde edilen geleneksel özelliklerin, modelin genel doğruluk oranını artırdığı gözlemlenmiştir. Özellikle dönme, ölçekleme ve kaydırma gibi geometrik dönüşümlere karşı modelin gösterdiği dayanıklılık, geleneksel özelliklerin entegrasyonunun model başarısına olan katkısını açıkça ortaya koymuştur. Öğrenme oranı planlayıcıları ve düzenleme teknikleriyle desteklenen bu hibrit yapı, farklı yöntemlerin güçlü yönlerini bir araya getirerek, görüntü sınıflandırma alanında etkili ve kararlı bir çözüm sunmuştur.

Önerilen hibrit modelin başarımı ve hesaplama verimliliği, literatürdeki modern hafif mimarilerden (lightweight architectures) biri olan MobileNetV3-Small ile kıyaslanmıştır. MobileNetV3, özellikle düşük işlem gücü gerektiren cihazlar için optimize edilmiş olsa da, genellikle yüksek çözünürlüklü girdiler (224x224) için tasarlanmıştır. Bu çalışmada adil bir kıyaslama yapabilmek adına, MobileNetV3 modeli ImageNet ağırlıkları kullanılarak transfer öğrenme (transfer learning) yöntemiyle başlatılmıştır. SVHN veri

setindeki 32x32 boyutlu görüntülerin, MobileNetV3 mimarisinde bilgi kaybına uğramadan işlenebilmesi için UpSampling katmanı kullanılarak boyutları 96x96'ya yükseltilmiş ve piksel değerleri 0-255 aralığına yeniden ölçeklendirilmiştir. Bu kıyaslama, önerilen yöntemin sadece doğruluk değil, aynı zamanda görüntü büyütme işlemine gerek duymadan sağladığı hız avantajını (ms) ortaya koymayı amaçlamaktadır.

DeneySEL sonuçların rastlantısal olmadığını kanıtlamak ve bilimsel güvenilirliği sağlamak amacıyla, tüm eğitim süreçleri (Hem Hibrit hem de MobileNetV3 için) 5 farklı rastgele çekirdek (seed) değeri (42, 123, 7, 2024, 99) kullanılarak tekrarlanmıştır. Modeller arasındaki performans farklarının istatistiksel olarak anlamlı olup olmadığını belirlemek için ise eşleştirilmiş t-testi (paired t-test) uygulanmış ve sonuçlar ortalama $\pm$ standart sapma olarak raporlanmıştır.

3.3. Modelin Eğitimi

Önerilen hibrit modelin eğitimi sürecinde, modelin genel başarısını artırmak ve aşırı öğrenmenin (overfitting) önüne geçmek amacıyla dikkatli bir hiperparametre seçimi ve çeşitli düzenleme teknikleri uygulanmıştır. Eğitim süreci, hem CNN mimarisi tarafından çıkarılan derin özelliklerin hem de Hu ve Zernike momentlerinden elde edilen geleneksel özelliklerin etkili bir şekilde birleştirilmesine dayanır. Bu bağlamda, modelin performansını optimize etmek için öğrenme oranı planlayıcıları, erken durdurma ve öğrenme oranı azaltma gibi callback mekanizmalarından da yararlanılmıştır. Modelin eğitimi, çalışmanın ana odak noktası olan SVHN veri kümesi üzerinde gerçekleştirilmiştir. 32x32 boyutundaki üç kanallı (RGB) görüntüler, CNN mimarisinin girdi verisi olarak kullanılmıştır. Görüntülerin piksel değerleri 0-255 aralığından 0-1 aralığına normalize edilerek modele daha stabil bir öğrenme süreci sağlanmıştır. Ayrıca, son sınıflandırma katmanında 10 sınıflı SVHN rakamlarının (0-9) tahmini gerçekleştirilmiştir.

Cosine Annealing Learning Rate Scheduler, modelin öğrenme oranını dinamik bir şekilde ayarlayarak optimizasyon sürecinde daha stabil bir performans elde edilmesini sağlamıştır. Bu planlayıcı, öğrenme oranını epoch sayısına bağlı olarak kosinüs fonksiyonuna göre ayarlamış, minimum ve maksimum değerler arasında dalgalanan bir öğrenme oranı belirlemiştir. Bu sayede model, lokal minimumlara takılmadan daha geniş bir parametre alanını keşfetme fırsatı bulmuştur. Kullanılan değerlendirme metrikleri modelin başarımı, eğitim ve doğrulama aşamalarında izlenen çeşitli metrikler aracılığıyla değerlendirilmiştir:

- Accuracy (Doğruluk): Modelin doğru sınıflandırma oranını gösterir.
- Loss (Kayıp): Modelin tahminleri ile gerçek etiketler arasındaki farkı ölçen bir fonksiyon. Categorical crossentropy kullanılmıştır.

Bu metrikler, modelin hem eğitim hem de doğrulama setindeki performansını izlemek için görselleştirilmiştir. Eğitim süreci boyunca kayıp ve doğruluk değerlerindeki değişimler, modelin genel başarısının takibini kolaylaştırmıştır. Kullanılan callback mekanizmaları modelin eğitim sürecinde aşırı öğrenmenin önüne geçmek ve öğrenme oranını etkili bir şekilde ayarlamak için çeşitli callback mekanizmalarından yararlanılmıştır:

- Early Stopping: Modelin doğrulama kaybı belirli bir süre boyunca iyileşme göstermediğinde eğitimi durdurarak aşırı öğrenmenin önüne geçmiştir. Bu yöntem, modelin gereğinden fazla epoch çalışmasını engelleyip, en iyi ağırlıkların korunmasını sağlamıştır.
- Cosine Annealing Learning Rate Scheduler: Öğrenme oranının epoch'lara göre dinamik bir şekilde dalgalanmasını sağlamış, optimizasyon sürecinin daha dengeli ve verimli ilerlemesine katkıda bulunmuştur.


Bu callback mekanizmalarının birleşimi, modelin hızlı ve etkili bir şekilde öğrenmesini sağlarken, aşırı uyum riskini de minimize etmiştir. Özellikle Cosine Annealing yöntemiyle desteklenen öğrenme oranı ayarlaması, modelin daha geniş bir parametre uzayını keşfetmesine yardımcı olmuştur. Eğitim sürecinin sonunda modelin performansı, eğitim ve doğrulama setindeki kayıp ve doğruluk grafikleri aracılığıyla görselleştirilmiş ve sınıflandırma raporu ile detaylandırılmıştır. Ayrıca, tahmin edilen ve gerçek etiketler arasındaki uyumu analiz etmek için karışıklık matrisi oluşturulmuş, modelin hangi sınıflarda ne kadar başarılı olduğu incelenmiştir. Bu analizler, modelin genel başarısını ve eksik yönlerini açıkça ortaya koyarak, hibrit yaklaşımın sınıflandırma performansına olan katkısını net bir şekilde göstermiştir.

4. DENEYLER VE ÇIKTILAR

Bu bölümde, önerilen hibrit modelin performansı, gürültülü ve zorlu koşulları temsil eden SVHN veri kümesi üzerinde değerlendirilmiş ve literatürdeki modern hafif (lightweight) mimarilerle kıyaslanmıştır. Modelin başarımı; doğruluk (accuracy), kayıp (loss) değerleri, sınıflandırma matrisi ve hesaplama maliyeti (çıkartım süresi) üzerinden analiz edilmiştir.

4.1. Modelin Öğrenme Dinamikleri ve Performans Analizi

Önerilen modelin eğitim süreci boyunca gösterdiği kararlılık ve öğrenme davranışı, kayıp ve doğruluk grafikleri üzerinden incelenmiştir. Şekil 1’de, eğitim ve doğrulama setleri üzerindeki kayıp değerlerinin değişimi sunulmuştur.



Şekil 1. Hibrit modelin eğitim ve doğrulama sürecindeki kayıp (loss) ve doğruluk (accuracy) değişimleri

Şekil 1’deki grafikler incelendiğinde, modelin eğitim ve doğrulama kayıplarının (Loss) birbirine paralel ve istikrarlı bir şekilde düştüğü görülmektedir. Yaklaşık 10. epoch’tan itibaren kayıp değerleri 0.35 seviyelerinde stabilize olmuştur. Doğruluk (Accuracy) grafiğinde ise modelin doğrulama seti üzerinde %90.97 seviyelerinde bir başarıma ulaştığı gözlemlenmiştir. Eğitim ve doğrulama eğrileri arasındaki farkın (gap) dar olması, modelin SVHN gibi yüksek gürültülü bir veri setinde dahi aşırı öğrenme (overfitting) probleminden kaçındığını ve güçlü bir genelleme yeteneğine sahip olduğunu kanıtlamaktadır.

Modelin sınıflandırma performansını daha detaylı analiz etmek amacıyla, test veri seti üzerindeki tahminler kullanılarak Karışıklık Matrisi (Confusion Matrix) oluşturulmuştur (Şekil 2).

Karışıklık Matrisi (SVHN)										
	0	1	2	3	4	5	6	7	8	9
0	1629	22	10	1	3	6	28	10	12	23
1	32	4870	23	34	52	11	18	48	7	4
2	12	38	3903	58	23	11	17	38	27	22
3	18	53	46	2539	8	62	21	14	30	91
4	12	69	18	10	2366	9	12	6	10	11
5	11	12	10	58	11	2216	34	6	12	14
6	51	21	4	25	17	42	1764	3	32	18
7	5	75	25	10	7	4	4	1878	4	7
8	33	19	7	55	19	20	135	2	1305	65
9	48	15	47	12	6	13	12	8	9	1425

Şekil 2. SVHN veri seti üzerinde hibrit modelin karışıklık matrisi

Şekil 2 incelendiğinde, modelin diyagonal eksenlerdeki yüksek yoğunluk, sınıfların büyük çoğunluğunun doğru tahmin edildiğini göstermektedir. Özellikle SVHN veri setindeki bulanık ve deforme olmuş rakamlara rağmen, modelin sınıf ayrıştırma başarısının yüksek olduğu görülmektedir. Hataların (matrisin diyagonal dışı elemanları) genellikle görsel olarak birbirine çok benzeyen sınıflar arasında (örneğin "1" ve "7" veya "3" ve "5") yoğunlaştığı, ancak bu hataların genel performansı düşürecek seviyede olmadığı tespit edilmiştir.

4.2. Hesaplama Maliyeti ve Modern Mimarilerle Kıyaslama

Çalışmanın temel katkılarından biri olan "verimlilik" analizini ortaya koymak amacıyla, önerilen Hibrit model; temel CNN mimarisi ve modern hafif mimarilerin en güçlü temsilcilerinden MobileNetV3-Small ile kıyaslanmıştır. Sonuçların güvenilirliğini sağlamak için tüm modeller 5 farklı rastgele çekirdek (seed) değeri ile test edilmiş ve ortalama sonuçlar Çizelge 2’de raporlanmıştır.

Çizelge 2. SVHN veri seti üzerinde performans ve hız kıyaslaması (ortalama $\pm$ standart sapma)

Model	Doğruluk (Ort. $\pm$ Std)	Çıkarım süresi (Inference time)	İstatistiksel fark (p-değeri)
CNN	%91.69 $\pm$ 0.09	603.93 ms	Anlamsız ($p > 0.05$)
MobileNetV3	%91.61 $\pm$ 0.74	3276.07 ms	Anlamsız ($p > 0.05$)
Önerilen hibrit	%90.97 $\pm$ 0.60	760.24 ms	-

Çizelge 2’deki veriler, doğruluk açısından modeller arasında istatistiksel olarak anlamlı bir fark oluşmadığını ($p > 0.05$) göstermektedir. Önerilen model, karmaşık MobileNetV3 mimarisiyle rekabetçi bir doğruluk oranına sahiptir. Ancak çalışmanın en kritik bulgusu hız analizinde ortaya çıkmıştır. MobileNetV3, yüksek çözünürlük (224x224) gerektiren yapısı nedeniyle görüntü büyütme (upsampling) işlemine ihtiyaç duymakta ve bu durum işlem süresini 3276.07 ms seviyesine çıkarmaktadır. Önerilen Hibrit model ise ham görüntü boyutunda (32x32) çalışarak aynı işlemi 760.24 ms sürede tamamlamaktadır. Bu sonuç, önerilen yöntemin MobileNetV3’ten yaklaşık 4.3 kat daha hızlı çalıştığını ve gerçek zamanlı uygulamalar için çok daha verimli (cost-effective) bir çözüm sunduğunu kanıtlamaktadır.

5. SONUÇ

Bu çalışmada, rakam sınıflandırma problemleri için derin öğrenme mimarileri ile geleneksel görüntü işleme tekniklerini (Hu ve Zernike Momentleri) birleştiren hibrit bir model önerilmiştir. Önerilen yaklaşım, CNN mimarisinin otomatik öznitelik çıkarma yeteneği ile Hu ve Zernike Momentlerinin geometrik değişmezlik (dönme ve ölçekleme direnci) özelliklerini entegre etmiştir. Modelin gürültüye ve geometrik bozulmalara karşı dayanıklılığını test etmek amacıyla, literatürdeki zorlu veri setlerinden biri olan SVHN kullanılmıştır. Deneysel sonuçlar, önerilen hibrit modelin %90.97 ortalama doğruluk oranıyla, modern MobileNetV3 mimarisi (%91.61) ile rekabetçi bir performans sergilediğini göstermiştir. Yapılan istatistiksel testler, iki model arasındaki doğruluk farkının anlamsız olduğunu ($p > 0.05$) ortaya koymuştur. Ancak çalışmanın en önemli bulgusu, hesaplama maliyeti analizinde görülmüştür. Önerilen hibrit yapı, MobileNetV3’e kıyasla 4 kattan fazla hız avantajı (760 ms’ye karşılık 3276 ms) sağlayarak, düşük donanım kaynağına sahip gömülü sistemler ve gerçek zamanlı uygulamalar için üstünlüğünü kanıtlamıştır. Elde edilen bulgular, geometrik özniteliklerin modele entegrasyonunun, doğruluktan ödün vermeden işlem yükünü hafiflettiğini doğrulamaktadır. Gelecek çalışmalarda, bu hibrit yaklaşımın Vision Transformer (ViT) gibi daha yeni nesil mimarilere entegrasyonu ve farklı nesne tanıma problemlerindeki etkinliği araştırılacaktır.

6. KAYNAKLAR

1. Patidar, P.K., Tomar, D.S., Pateriya, R.K. & Sharma, Y.K. (2023). Precision agriculture: Crop image segmentation and loss evaluation through drone surveillance. *2023 Third International Conference on Secure Cyber Computing and Communication (ICSCCC)*, Jalandhar, India, 495-500.
2. Wang, Y. (2025). Deep learning based image classification algorithm. *In 2025 IEEE 5th International Conference on Power, Electronics and Computer Applications (ICPECA)*, 505-509. IEEE.
3. 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*, 770-778.

4. LeCun, Y., Bottou, L., Bengio, Y. & Haffner, P. (2002). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
5. Tomar, A. & Patidar, H. (2023). Optimizing CNN model performance for MNIST and CIFAR classification using rectified sigmoid and ReS activation functions. In *2023 7th International Conference On Computing, Communication, Control and Automation (ICCUBE)*, 1-6. IEEE.
6. Singh, B.K., Rai, A., Kundu, K., Kalita, K. & Agrawal, R. (2024). An empirical analysis of invariance Hu's moment feature over a digital image. In *2024 11th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, 1-5. IEEE.
7. Lai, Z., Yao, Z., Lai, G., Wang, C. & Feng, R. (2024). A novel face swapping detection scheme using the Pseudo Zernike transform based robust watermarking. *Electronics*, 13(24), 4955.
8. Lei, G., Lai, W., Meng, Q., Liu, H., Shi, D., Cui, W. & Han, K. (2023). Efficient and noise-resistant single-pixel imaging based on Pseudo-Zernike moments. *Optics Express*, 31(24), 39893-39905.
9. Fu, D., Zhou, X., Xu, L., Hou, K. & Chen, X. (2023). Robust reversible watermarking by fractional order Zernike moments and pseudo-Zernike moments. *IEEE Transactions on Circuits and Systems for Video Technology*, 33(12), 7310-7326.
10. Jusman, Y., Anam, M.K., Puspita, S. & Saleh, E. (2021). Machine learnings of dental caries images based on Hu moment invariants features. In *2021 International Seminar on Application for Technology of Information and Communication (iSemantic)*, 296-299. IEEE.
11. Zheng, N., Zhang, G., Zhang, Y. & Sheykhahmad, F.R. (2023). Brain tumor diagnosis based on Zernike moments and support vector machine optimized by chaotic arithmetic optimization algorithm. *Biomedical Signal Processing and Control*, 82, 104543.
12. Gül, E. & Bilgiç, S. (2025). Secret image hiding method based on multi-cover image with stego image sequence detection using perceptive hash. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 40(4), 927-936.
13. Wan, G. & Yao, L. (2023). LMFRNet: A lightweight convolutional neural network model for image analysis. *Electronics*, 13(1), 129.
14. AbuRass, S., Huneiti, A. & Al-Zoubi, M.B. (2020). Enhancing convolutional neural network using Hu's moments. *International Journal of Advanced Computer Science and Applications*, 11(12), 130-137.
15. Ala, M., Şahin, M., Kılıç, M. & Dişken, G. (2025). An investigation on design criteria of heat exchangers by using tree models of machine learning methods. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 40(2), 375-386.