

Türkiye Cumhuriyeti'nin ilk Beş Emisyon Banknotunun Tanınması için Xception, CNN ve Yolo Görüntü İşleme Algoritmaları Kullanılarak Mobil Uygulamanın Geliştirilmesi

Development of a Mobile Application Using Xception, CNN, and Yolo Image Processing Algorithms for the Recognition of the First Five-Item Banknotes of the Republic of Türkiye

Müyesser ŞENYÜZ

MCBÜ, Hasan Ferdi Turgutlu Teknoloji
Fakültesi
Yazılım Mühendisliği Bölümü
Manisa/Türkiye
muyessersenyuz@gmail.com
ORCID: 0009-0004-3348-4299

Fatih Berkant EREN

MCBÜ, Hasan Ferdi Turgutlu
Teknoloji
Fakültesi
Yazılım Mühendisliği Bölümü
Manisa/Türkiye
fatihberkant38@gmail.com
ORCID: 0009-0000-3849-8885

Emin BORANDAĞ

MCBÜ, Hasan Ferdi Turgutlu Teknoloji
Fakültesi
Yazılım Mühendisliği Bölümü
Manisa/Türkiye
emin.borandag@cbu.edu.tr
ORCID: 0000-0001-5553-2707

Öz

Günümüzde derin öğrenme algoritmaları, yüksek doğruluk ve başarımları sayesinde pek çok farklı alanda etkin bir şekilde kullanılmaktadır. Bu algoritmalar arasında özellikle CNN, Xception ve YOLOv8 modelleri görüntü işleme alanında öne çıkmaktadır. Temel bir derin öğrenme algoritması olan CNN modeli, geniş bir katnak desteğine sahip olup yüz tanıma ve metin sınıflandırma dahil birçok uygulama alanında sıklıkla tercih edilmektedir. Xception modeli, derin öğrenmedeki gelişmiş yaklaşımla karmaşık görüntü özellikleri üzerinde verimli sonuçlar sunarken; YOLOv8 modeli, hızlı ve doğru nesne algılama yeteneğiyle dikkat çekmektedir. Bu modellerin sergilediği yüksek başarımları, tarihi belgelerin sayısal olarak tanınması ve sınıflandırılması gibi özel alanlarda başarıyla uygulanmalarına olanak tanımaktadır. Bu çalışma kapsamında, veri kazıma yöntemi kullanılarak Türkiye Cumhuriyeti'nin ilk beş emisyonuna ait banknot görüntüleri derlenmiş ve 9304 görüntüden oluşan özgün bir veri kümesi oluşturulmuştur. Söz konusu veri kümesi; CNN, YOLOv8 ve

Xception derin öğrenme algoritmaları kullanılarak eğitilmiştir. Analizler sonucunda; CNN, Xception ve YOLOv8 modelleri için doğruluk oranları sırasıyla 0,72; 0,86 ve 0,99 olarak hesaplanmıştır. Model eğitiminin yanı sıra, çalışma kapsamında YOLOv8 yapay zeka algoritmasının entegre edildiği ve mobil cihazlarda çalışabilen bir yazılım geliştirilmiştir. Bu sayede, numismatik meraklıları veya koleksiyonerler, çektikleri fotoğrafları yükleyerek banknotları emisyon bazında sınıflandırabilmektedir. Ayrıca bu çalışma, banknotların temsil ettiği dönemin sanat, mimari ve sosyal dokusuna dair izler taşıyan tarihi mirasın tanımlanması ve gelecek nesillere aktarılmasında kritik bir rol oynamaktadır. Sonuç olarak bu çalışma, elde edilen yüksek sınıflandırma başarımlarıyla, tarihi belgelerin sayısal ortama aktarılmasında derin öğrenme teknolojilerinin sahip olduğu potansiyeli ortaya koymuştur.

Anahtar sözcükler: Görüntü İşleme, Derin Öğrenme, YOLOv8, CNN, Xception

Abstract

Nowadays, deep learning algorithms are used effectively in many diverse areas due to their high accuracy and performance. Among these algorithms, CNN, Xception, and YOLOv8 models stand out in the field of image processing. The CNN model, as a basic deep learning algorithm, has extensive literature support and is frequently used in many application areas, including face recognition and text classification. While the Xception model is used efficiently on complex image features with a more sophisticated approach in deep learning,

Makale Bilgileri

Türü: Araştırma
Geliş tarihi: 25.02.2025
Kabul tarihi: 13.11.2025

Article Info

Type: Research
Received date: 25.02.2025
Accepted date: 13.11.2025

Atıf/ to Cite (IEEE): M. ŞENYÜZ, F. B. EREN, E. BORANDAĞ, Türkiye Cumhuriyeti'nin ilk Beş Emisyon Banknotunun Tanınması için Xception, CNN ve Yolo Adlı Görüntü İşleme Algoritmaları Kullanılarak Mobil Uygulamanın Geliştirilmesi: Bilgisayar Bilimleri ve Mühendisliği Dergisi, Cilt 19 2026 Sayı-19-1. Sf: 1-9,
DOI: 10.54525/bbmd.1646627

the YOLOv8 model, however, is highly popular for its fast and accurate object detection. The high performance of these models enables them to be used successfully in particular domains, such as digital recognition and classification of historical documents This study created images of the first five emission banknotes of the Republic of Türkiye using the data scraping approach and generated a new dataset consisting of 9304 images. It also trained the new dataset using CNN, YOLOv8, and Xception deep learning algorithms. As a result, the study calculated truth value rates of 0.72, 0.86 and 0.99 for the CNN, Xception, and Yolov8 models, respectively. In addition to performing model training, the present study also developed software that can run on mobile devices with the embedded YOLOv8 artificial intelligence algorithm. Hence, old money enthusiasts may classify emission-based banknotes by uploading the photos they took. The present study also plays a critical role in identifying and transferring historical heritage that bears traces of the era to which banknotes belong in terms of art, architecture, and social aspects. As a result, this study revealed the potential of deep learning technologies in the digital recognition of historical documents, with the high classification performance it attained.

Keywords: Image Processing, Deep Learning, YOLOv8, CNN, Xception

1. Giriş

Teknolojideki son gelişmeler, belgelerin yazılım aracılığıyla sınıflandırılması ve arşivlenmesi noktasında çeşitli olanaklar sunmuştur. Bu yazılım uygulamaları, sayısal ortamlarda belge sınıflandırma süreçlerini kolaylaştırmaktadır. Ayrıca, eski ve okunması güç belgelerin korunmasına imkan tanıyarak, muhafazası veya sınıflandırılması gereken belgelerin sayısal ortama sorunsuz bir şekilde aktarılmasını sağlamaktadır. Bu nitelikli yazılım uygulamaları sayesinde; belgelere hızlı erişim, veri güvenliği ve veri tutarlılığı gibi pek çok üstünlük elde edilmektedir [1]. Türkiye Cumhuriyet Merkez Bankası (TCMB); para basma, senyora geliri elde etme ve para ihraç etme yetkisine sahip tek kurumdur. Tarihsel süreçte, Türkiye Büyük Millet Meclisi'nden (TBMM) aldığı yetkiyle ulusal finansal bağımsızlığın güvencesi olmuştur. Bu bağlamda, Cumhuriyet'in ilk yıllarından başlayarak dolaşımda olan banknotlar, ekonomik bağımsızlığın ve ulusal kimliğin inşa edilmesinde kritik bir rol oynamıştır. Güncel teknolojilerin kullanımıyla birlikte, Merkez Bankası'nın bu tarihi mirası zaman içerisinde korunmuş ve sayısallaştırılmıştır [2]. Bu çalışma, veri kazıma yöntemiyle Türkiye Cumhuriyeti'nin ilk beş emisyonuna ait banknot görüntülerini elde etmiş ve 9304 görüntüden oluşan yeni bir veri kümesi oluşturmuştur. Mevcut çalışma; Türkiye Cumhuriyeti tarafından ihraç edilen ilk beş emisyon banknotun, derin öğrenme algoritmaları olan YOLO, Xception ve CNN kullanılarak sayısal ortamda tanımlanmasını ve sınıflandırılmasını amaçlamaktadır. Çalışma sonucunda doğruluk değerleri CNN için 0,72; Xception için 0,86 ve YOLOv8 için 0,99 olarak hesaplanmıştır. En yüksek başarıyı sergileyen YOLOv8 algoritması kullanılarak geliştirilen mobil uygulama, akıllı telefon kamerasıyla çekilen banknot görüntülerini tanımlayabilmekte ve ilgili banknota

ilişkin teknik ayrıntıları sunabilmektedir. Uygulamada yer alan banknotlar, ilgili oldukları dönemin tarihi olaylarını, mimari özelliklerini ve kültürel bilgilerini yansıtmaları bakımından kültürel mirasın tanıtılması ve aktarılması açısından büyük önem taşımaktadır. Çalışmanın alana sağladığı diğer temel katkılar aşağıda listelenmiştir:

- Görüntü işleme algoritmaları vasıtasıyla eski belgelerin sınıflandırılması amacıyla üç farklı derin öğrenme modelinin oluşturulması ve Türkiye Cumhuriyeti'nin ilk beş emisyonuna ait banknotların sayısal ortamda tanınmasının sağlanması.
- Web kazıma yöntemi kullanılarak 9304 adet görüntünün derlenmesi ve bu görüntülerden özgün bir veri kümesi oluşturulması.
- YOLO, Xception ve CNN algoritmalarıyla geliştirilen modellerin başarı oranlarının tespit edilmesi ve en yüksek başarıya sahip model temel alınarak bir mobil uygulama geliştirilmesi. Söz konusu mobil uygulama, cihaz kamerasıyla çekilen fotoğraflardaki banknotu tanımakta ve kullanıcıya banknota ilişkin ayrıntılı teknik bilgiler sunmaktadır.

Derin öğrenme algoritmalarına dayanan bu çalışma, banknotların taşıdığı tarihi ve kültürel mirası korumayı ve modern teknolojilerle hızlı ve güvenilir bir tanıma sistemi kurmayı amaçlamıştır. Proje ayrıca, kullanılan yöntemler aracılığıyla görüntü işleme alanındaki bilgi birikimini genişletmeyi ve benzer projeler için bir altyapı oluşturmayı hedeflemektedir. Giriş bölümü dışında bu çalışma dört ana kısımdan oluşmaktadır: Bölüm 2 ilgili kaynakları; Bölüm 3 çalışmada kullanılan algoritmaları; Bölüm 4 ise geliştirilen sistemi ele almakta; son bölüm ise elde edilen bulguları sunmaktadır.

2. İlgili Çalışmalar

Makine öğrenimi ve derin öğrenme algoritmaları, sundukları yüksek sınıflandırma başarıları sayesinde sağlık, borsa, tarım ve savunma sanayii gibi pek çok farklı disiplinde yaygın olarak kullanılmaktadır. Kaynak taraması sonucunda, bu konuyla ilgili yakın dönemde gerçekleştirilen çeşitli çalışmalar tespit edilmiştir. Örneğin Aksoy ve ark. (2021), derin öğrenme algoritmalarını görüntü işleme ve yapay zeka teknikleriyle birleştirerek İnsansız Hava Araçlarının (İHA) yangınların erken tespitindeki potansiyelini araştırmıştır. Çalışmada orman ve şehir yangınlarının artan riskine dikkat çekilmiş ve erken tespit için İHA tabanlı bir mekanizma önerilmiştir [3]. Özdet ve ark. (2022), bilgisayarlı tomografi (BT) görüntülerine odaklanarak akciğer kanserinin erken teşhisinde ve tümör tespitinde makine öğrenimi algoritmalarının kullanımını rapor etmiştir [4]. Eldem ve ark. (2017), güvenlik sistemlerinde yüz tanıma uygulamalarına yönelik görüntü işleme tekniklerini tartışmış; OpenCV kütüphanesi kullanarak %79 başarı oranına sahip bir sistem geliştirmiştir [5]. Binalardaki çatlakların yapısal güvenliğe yönelik oluşturduğu tehditlerden yola çıkan Üncü ve ark. (2023), CNN tabanlı bir derin öğrenme algoritması kullanarak bu çatlakların tespiti için %95'in üzerinde başarı

sağlayan bir ölçüm sistemi geliştirmiştir [6]. Benzer şekilde Karasulu ve ark. (2023), bireylerin kulak görüntülerinden cinsiyet tahmini yapmayı amaçlamış ve %85'in üzerinde bir başarı oranına ulaşmıştır [7]. Kiran ve ark. (2022) ise YOLOv5 ve Xception algoritmalarını kullanarak gemi fotoğraflarını %96'nın üzerinde bir doğrulukla sınıflandırmayı başarmıştır [8]. Son yıllarda para tanıma sistemleri üzerine yapılan çalışmalar incelendiğinde; Şahin (2017), yapay sinir ağları kullanarak banknot veri kümelerini eğitmiş ve görme engelli bireyler için sesli bildirim sağlayan bir uygulamada 1,0 doğruluk değerine ulaşan ResNet50 modelini kullanmıştır [9]. Gülçin ve ark. (2018), mevcut Türk banknotlarını derin evrişimli sinir ağları ile eğitmiş ve DenseNet-121 mimarisiyle %93,15 başarı oranı elde etmiştir [10]. Gencal (2023), SIFT ve SURF yöntemlerini kullanarak Türk madeni paralarının tanınması üzerine bir bilgisayar görmesi çalışması yürütmüş ve SURF yönteminin daha başarılı sonuçlar verdiğini saptamıştır [11]. Yeşiltepe ve ark. (2024), Türk banknotlarını sınıflandırmak için geliştirdikleri modellerde DenseNet201 mimarisi ile %98,84 doğruluk oranına ulaşmıştır [12]. Makaklı ve ark. (2024), banknotların dönemin kültürel ve mimari yapısını yansıtan materyaller olarak önemini vurgulamış ve emisyonları sosyal ve kültürel açıdan inceleyen tamamlayıcı bir analiz yöntemi sunmuştur [13]. Özgür ve ark. (2021) ise görme engelliler için para tanıma ve döviz kuru dönüştürme işlemlerini gerçekleştiren bir uygulama geliştirmiş ve uygulama için SIFT yaklaşımının ideal olduğunu belirlemiştir [14].

3. Yöntem

Bu bölüm, çalışmada kullanılan algoritmaları ve teknik başarı ölçülerini kapsamaktadır.

3.1 CNN

CNN, özellikle bilgisayarlı nesne algılama, nesne takibi ve görüntü işleme alanlarında yaygın olarak kullanılan bir derin öğrenme algoritmasıdır. CNN mimarisi, görüntülerdeki örüntü tanıma ilkesine dayandığından, nesne tanıma sorunlarının çözümünde sıklıkla tercih edilmektedir [15]. CNN mimarisinin temel yapı taşlarını; evrişimli katmanlar, havuzlama katmanları ve tam bağlantılı katmanlar oluşturur. Evrişimli katman, görüntüdeki özellikleri öğrenmek için çekirdek filtreleri kullanarak belirli desenleri algılar. Havuzlama katmanları, işlem yükünü azaltırken modelin genelleme kapasitesini artırır. Tam bağlantılı katmanlar ise çıkarılan bu özellikleri sınıflandırma veya tahmin amacıyla kullanır. CNN, öğrenme sürecini geri yayılım ve gradyan inişi gibi optimizasyon algoritmalarıyla gerçekleştirir. Ayrıca model başarımını artırmak ve aşırı uyum sorununun önüne geçmek için veri artırma, bırakma ve ağırlık düzenleme gibi tekniklerden yararlanılabilmektedir [16].

3.2 Xception

Xception mimarisi, klasik başlangıç yapısını geliştiren ve daha verimli hale getiren bir derin öğrenme algoritmasıdır. F. Chollet tarafından 2017 yılında geliştirilen bu mimari, model parametrelerini etkin kullanması sayesinde daha az donanım gereksinimi ile daha kısa sürede model oluşturulmasına

olanak tanır [17]. Xception modelinin giriş formatı 299x299 benek boyutunda RGB görüntülerdir. Özellik çıkarma için kullanılan 36 evrişimli katman ile toplam 126 katman derinliğine sahiptir. Parametre sayısını optimize etmek amacıyla tam bağlantılı katman yerine global ortalama havuzlama katmanı kullanılır ve tahmin çıktısı softmax fonksiyonu aracılığıyla elde edilir. Söz konusu 36 evrişimli katman; ilk ve son modüller hariç, doğrusal geçiş bağlantılarıyla birbirine bağlı 14 modül şeklinde yapılandırılmıştır. Bu katmanlar; giriş, orta ve çıkış akışları olmak üzere üç ana bileşene ayrılır. Veri önce giriş akışından geçer, ardından sekiz kez tekrarlanan orta akıştan ve son olarak çıkış akışından süzülür. Giriş akışı 8, orta akış 24 (8x3) ve çıkış akışı 4 evrişimli katmandan oluşmaktadır [18,19].

3.3. YOLO

YOLO algoritmasının temel amacı, görüntülerdeki nesneleri tanıyıp sınıflandırırken her bir nesnenin konumunu eş zamanlı olarak belirlemektir. Diğer nesne algılama yöntemlerinden farklı olarak YOLO, görüntünün tamamını tek bir ileri beslemeli ağ kullanarak tek seferde işler; bu da algoritmayı oldukça hızlı ve verimli kılar. Bu özellik, video işleme ve güvenlik kameraları gibi gerçek zamanlı uygulamalarda önemli bir avantaj sağlar. YOLO; güvenlik, otonom araçlar, endüstriyel otomasyon ve akıllı şehirler gibi geniş bir kullanım yelpazesine sahiptir. Küçük nesnelerde ve karmaşık arka planlarda doğruluk oranı düşebilse de algoritmanın farklı sürümleriyle bu zorluklar büyük ölçüde aşılmış ve başarımlar optimize edilmiştir. Farklı uygulama gereksinimlerine hitap eden çeşitli YOLO versiyonları, doğruluk, hız ve esneklik açısından yüksek etkinlik sunmaktadır [19,20].

4. Uygulama

Bu bölümde; derlenen veri kümesi, oluşturulan derin öğrenme modelleri, modellerden elde edilen başarımlar ve çalışma kapsamında geliştirilen yazılımın detayları sunulmaktadır.

4.1 Veri Kümesi

Çalışmada, araştırmanın konusunu oluşturan 1926 - 1971 yılları arasındaki ilk beş emisyonla ilişkin banknot görüntülerini tanımlamak amacıyla Python kitaplığı olan BeautifulSoup kullanılmıştır [21]. Söz konusu kitaplık; HTML etiketlerini ayırtmak, web kazıma işlemlerini yürütmek, web sayfası içeriğinden filtrelenecek verileri çekmek, görüntüleri etiketlemek ve toplanan verileri analiz etmek için kullanılmıştır [22]. Veri ön işleme aşamasında, oluşturulan veri kümesinde yinelenen görüntülerin bulunmadığından emin olmak için bir kontrol mekanizması uygulanmıştır. Bu kontrol, veri kümesine eklenen dosyaların farklı boyutlarda olduğunun doğrulanmasıyla sağlanmıştır. Elde edilen fotoğraflardan üretilen veri kümesine ilişkin ayrıntılar Çizelge-1'de sunulmuştur.

Çizelge-1: Veri Kümesi

Emisyon Sırası	Para Birimi Türü	Kupür	Basım Tarihleri	Görüntü Sayısı
----------------	------------------	-------	-----------------	----------------

1. Emisyon	7 Tip	1, 5, 10, 50, 100, 500 ve 1000 TL	1926-1936	1379
2. Emisyon	9 Tip	0.50 ,1, 2,5, 5, 10, 50, 100, 500 ve 1.000 TL	1937-1944	3017
3. Emisyon	7 Tip	2.50, 10, 50, 100, 500 ve 1000 TL	1942-1947	2048
4. Emisyon	1 Tip	1000 TL	1947-1948	753
5. Emisyon	7 Tip	2.5, 5, 10, 50, 100, 500 ve 1.000 TL	1951-1971	2107

Çalışmada modellerin aşırı uyum eğilimini azaltmak ve genelleme yeteneklerini artırmak amacıyla veri artırma tekniklerine başvurulmuştur. Bu yaklaşım, doğal fotoğraf çekimi veya banknotların yıpranması sonucu oluşabilecek kontrast, parlaklık ve bulanıklık gibi görsel değişimlere karşı modelin dayanıklılığının değerlendirilmesine olanak tanımıştır.

Çalışma kapsamında dört farklı veri artırma grubu uygulanmıştır.

- Geometrik Dönüşümler: Yatay Çevirme, Dikey Çevirme, Döndürme, Elastik Dönüşüm, Izgara Bozulması ve Optik Bozulma.
- Fotometrik Dönüşümler: Rastgele Parlaklık Kontrastı, Ton Doygunluk Değeri, RGB Kaydırma ve Rastgele Gama.
- Gürültü ve Bulanıklık: Gauss Gürültüsü ve Bulanıklık.
- Görüntü İyileştirme: Uyarlanabilir Histogram Eşitleme (CLAHE) ve Kanal Karıştırma.

Veri ön işleme aşamasında, eğitim ve sınav kümelerinin aynı görüntüleri içermemesini sağlamak amacıyla yapılan dosya boyutu kontrolüne ek olarak, farklı işleme yöntemleriyle üretilen görüntülerin asıl görüntülerle karışmasını önlemek için küme ayırma işlemi gerçekleştirilmiştir. Özellikle, modelin işlenmiş görüntülere karşı genelleme başarımını ölçmek amacıyla, yüksek düzeyde gürültü veya işleme içeren bir alt küme sınav kümesine dahil edilmiştir.

4.2. Model Eğitimi

Toplanan 9304 görüntünün %80'i eğitim, %20'si ise sınav amacıyla ayrılmıştır. Model eğitimi için tercih edilen Python kodları Colab ortamında çalıştırılmıştır. Xception ve CNN modellerinin eğitim sürecinde beş farklı kitaplık kullanılmıştır: TensorFlow, Scikit-learn, Matplotlib, NumPy ve Seaborn. TensorFlow, yapay zeka ve derin öğrenme modellerinin geliştirilmesinde sıklıkla tercih edilen bir kitaplık olup sinir ağı çalışmaları için ideal bir seçenektir. Scikit-learn kitaplığı; sınıflandırma, regresyon ve kümeleme gibi makine öğrenimi işlevlerinin yürütülmesini kolaylaştırmaktadır. Matplotlib

verilerin grafiksel görselleştirilmesinde kullanılırken, çok boyutlu dizilerle çalışmaya olanak tanıyan NumPy, TensorFlow gibi kitaplıklarının temelini oluşturmaktadır. Seaborn kitaplığı ise Matplotlib tabanlı istatistiksel grafikler çizmek için tercih edilmiştir; Matplotlib'e kıyasla daha estetik bir görünüm sunmakta, sıcaklık haritaları ve dağılım diyagramları gibi karmaşık grafiklerin basitçe çizilmesine imkan vermektedir. YOLO algoritması da CNN ve Xception gibi NumPy ve Matplotlib kitaplıklarından yararlanmaktadır. Ancak buna ek olarak Ultralytics, OpenCV ve PyTorch kitaplıklarını da kullanmaktadır. Ultralytics, YOLO algoritmasının resmi Python paketi olup model eğitimi, tahmini ve sınavı için uygundur. OpenCV; görüntü işleme, video işleme ve çizim (kutu çizimi ve etiket yazma gibi) işlemlerinde öne çıkmaktadır. PyTorch ise YOLOv8 modellerinin arka planda çalışmasını sağlayan temel derin öğrenme kitaplıklarından biridir.

Araştırmada sınamalar tek bir derin öğrenme algoritması yerine üç farklı algoritma üzerinde gerçekleştirilmiştir. Algoritma seçiminde, kaynaklarda en yüksek doğruluk oranlarını sağlayan CNN, Xception ve YOLOv8 görüntü işleme algoritmaları tercih edilmiştir. Her denemede aynı öğrenme oranı kullanılmıştır. Gereksiz aşırı eğitimi önlemek amacıyla erken durdurma yöntemi uygulandığından, epok değerleri değişkenlik göstermiştir. YOLOv8 yöntemi Adam optimizasyon algoritmasını içermediği için varsayılan olarak SGD optimizasyon algoritması seçilmiştir. Çizelge-2, çalışmada kullanılan algoritmaların üst değiştirelerini içermektedir.

Çizelge – 2: Melez Değiştireler

Algoritma Adı	Öğrenme Oranı	Toplu İşlem Boyutu	Döngü Sayısı	Optimize Edici Adı	Kayıp Fonksiyon Adı
CNN	0,01	16	20	Adam	Categorical Crossentropy
Xception	0,01	16	22	Adam	Sparse Categorical Crossentropy
Yolov8	0,01	16	25	SGD	CloU Loss Binary Cross Entropy

CNN ve Xception modellerinde Ulamsal Çapraz Entropi kayıp fonksiyonu kullanılmıştır [23]. Ulamsal Çapraz Entropi, modelin her bir sınıf için tahmin ettiği olasılık dağılımı ile gerçek dağılım arasındaki farkı ölçer ve her sınıfın ayrı bir Ulam olarak ele alındığı durumlarda tercih edilir. Xception modeli için ayrıca Seyrek Ulamsal Çapraz Entropi kayıp fonksiyonundan da yararlanılmıştır. Seyrek Ulamsal Çapraz Entropi, dahili olarak tek kodlama dönüşümünü gerçekleştirir ve model tarafından öngörülen olasılık dağılımını kullanır [24]. YOLOv8 modeli için ise CloU Kaybı ve İkili Çapraz Entropi kayıp fonksiyonları kullanılmıştır. CloU Kaybı, nesne algılama görevlerinde sınırlayıcı kutu tahmini için kullanılan bir fonksiyon olup daha doğru ve kararlı kutu regresyonu elde edilmesini sağlar [25]. İkili Çapraz Entropi [26] ise bir hücrede nesne bulunup bulunmadığını tahmin etmek, yani her bir

nesne için güven puanı üretmek ve sınıflandırma yapmak amacıyla kullanılmıştır. Sonuçlar karşılaştırıldığında, CNN modelindeki Ulamsal Çapraz Entropi fonksiyonunun, Xception modelindeki Seyrek Ulamsal Çapraz Entropi fonksiyonuna göre daha düşük bir kayıp değeri verdiği görülmüştür. Bu bağlamda; CNN ve Xception modelleri hem Ulamsal Çapraz Entropi hem de Seyrek Ulamsal Çapraz Entropi kullanılarak eğitilmiş ve modellerdeki nihai kayıp fonksiyonu bu ön test değerlerine göre belirlenmiştir.

CNN ve Xception modellerinin optimizasyonu için Stokastik Gradyan İnişi (SGD), Uyarlanabilir Moment Tahmini (Adam) ve Kök Ortalama Kare Yayılımı (RMSprop) algoritmaları sınanmıştır. Her iki modelde de Adam optimizasyon algoritması, model başarımı açısından en başarılı sonucu vermiştir. Ayrıca YOLO modelinde varsayılan olarak kullanılan AdamW optimizasyon algoritması ile de yüksek başarımlar elde edilmiştir.

Girdi olarak yaklaşık 299x299 beneklik renkli görüntüleri işleyen model; sırasıyla 32, 64, 128 ve 256 filtreye sahip dört Conv2D katmanından oluşmaktadır. Her evrişimli katman işleminden sonra uygulanan 2x2 Max-Pooling işlemi boyut küçültmeyi sağlar. Düzleştirme katmanı, 3D çıktıyı tam bağlantılı (yoğun) katmanlara aktarmadan önce tek boyutlu hale getirir. 1024 nöronlu yoğun bir katmanın ardından, sınıflar için softmax aktivasyonlu bir çıktı katmanı kullanılarak çok sınıflı sınıflandırma gerçekleştirilir. Çizelge-3, oluşturulan modelin katman yapısına ilişkin verileri sunmaktadır.

Çizelge – 3: 2D CNN'in ağ modeli

Tabaka	Çıkış şekli
Conv2D (32 filtre, 3x3)	(Yok, 297, 297, 32)
MaxPooling2D (2x2)	(Yok, 148, 148, 32)
Conv2D (64 filtre, 3x3)	(Yok, 146, 146, 64)
MaxPooling2D (2x2)	(Yok, 73, 73, 64)
Conv2D (128 filtre, 3x3)	(Yok, 71, 71, 128)
MaxPooling2D (2x2)	(Yok, 35, 35, 128)
Conv2D (256 filtre, 3x3)	(Yok, 33, 33, 256)
MaxPooling2D (2x2)	(Yok, 16, 16, 256)
Flatten	(Yok, 65536)
Dense (1024 birim)	(Yok, 1024)
Dense (6 birim, softmax)	(Yok e, 6)

4.3. Model Sonuçları

Laboratuvar denemeleri sonucunda, YOLOv8 modelinin %94 doğru sınıflandırma oranına ulaştığı; banknotların nominal değerini ve ait olduğu emisyonu doğru bir şekilde belirlediği tespit edilmiştir. Öte yandan Xception ve CNN algoritmaları, YOLOv8'e kıyasla daha düşük başarı oranları sergilemiştir. Eğitim ve sınav süreçlerine ilişkin sonuçlar Çizelge-4 ve Çizelge-5'te sunulmuştur.

Çizelge-4 Model Eğitim Sonuçları

Algoritma İsimleri	Hassasiyet	Geri Çağırma	F-Skoru	Doğruluk
CNN	0,68	0,62	0,60	0,62
Yolo-v8	0,96	0,98	0,96	0,94
Xception	0,87	0,86	0,86	0,89

Çizelge -5 Model Sınama Sonuçları


Algoritma İsimleri	Hassasiyet	Geri Çağırma	F-Skoru	Doğruluk
CNN	0,73	0,72	0,72	0,72
Yolo-v8	0,99	0,99	0,99	0,99
Xception	0,88	0,86	0,87	0,86

Çalışmada, CNN ve özellikle YOLOv8 modellerinin sınav doğruluklarının eğitim doğruluklarından daha yüksek olduğu gözlemlenmiştir. Derin öğrenme kaynaklarında genellikle eğitim doğruluğunun sınav doğruluğundan yüksek olması beklense de mevcut durum eğitim sürecinde uygulanan düzenleme tekniklerinden kaynaklanmaktadır. Aşırı uyumu önlemek amacıyla eğitim sırasında kullanılan bırakma tekniği, modelin eğitim doğruluğunu bir miktar düşürmektedir. Sınav aşamasında bu mekanizmaların devre dışı bırakılması, modelin tam kapasiteyle çalışmasına olanak tanımış ve daha yüksek başarımlar elde edilmesini sağlamıştır. Özellikle YOLOv8 mimarisine ele alındığında, modelin nesneyi (banknotu) konumlandırma ve sınıflandırma kabiliyeti, sınav kümesindeki yüksek kaliteli veya düşük gürültülü örneklerde üstün başarımlar göstermiş; bu da sınav doğruluğunun eğitim doğruluğunu aşmasına yol açmıştır. Bu bulgu, modelin farklı kümelerine karşı güçlü bir genelleme yeteneğine sahip olduğunu kanıtlamaktadır. YOLOv8'in sınıflandırma başarısı, görüntünün tamamı yerine doğrudan algılanan nesneye odaklanması sayesinde parlaklık veya gürültü gibi arka plan değişimlerinden en düşük düzeyde etkilenmektedir. Karmaşık fotoğraf koşullarında dahi 0,99 gibi yüksek bir sınav doğruluğunun korunabilmesinin temel nedenlerinden biri budur.




Şekil-1 Örnek Sınıflandırma Sonucu


Şekil-2-7, elde edilen modellere ait ROC grafiklerini göstermektedir.




Şekil-2: CNN eğitimi ROC sonuçları




Şekil-5: Xception sınaması ROC sonuçları




Şekil-3: CNN sınaması ROC sonuçları



Şekil-6: Yolo sınaması ROC sonuçları




Şekil-4: Xception eğitimi ROC sonuçları




Şekil-7: Yolo eğitimi ROC sonuçları


Şekil 8-13 arasında elde edilen modellere ait karmaşıklık matrisi gösterilmektedir.




Şekil-8: CNN eğitim karmaşıklık matrisi




Şekil-9: CNN Sınaması karmaşıklık matrisi




Şekil-10: Xception eğitimi karmaşıklık matrisi



Şekil-11: Xception sınaması karmaşıklık matrisi



Şekil-12: Yolo eğitim karmaşıklık matrisi



Şekil-13 Yolo sınaması karmaşıklık matrisi

Şekil-1'de gösterildiği üzere model; sınıflandırma işlemini emisyon serilerine özgü nominal değer, renk tonu ve desen farklılıklarını dikkate alarak gerçekleştirmiştir. Model; özellikle portre konumları, arka plan desenleri, yazı tipleri ve renk yoğunluğu parametreleri üzerinden banknot emisyonları arasındaki farkları öğrenmiştir. Bu karakteristik özellikler, modelin "3. Emisyon 10 Lira" gibi tahminleri %95 gibi yüksek bir güven oranıyla yapmasını sağlamıştır. Bu durum; banknotların görsel yapısındaki gravür çizgileri, mikro metinler ve güvenlik şeridi gibi ayırt edici unsurların sınıflandırma başarımına doğrudan katkıda bulunduğunu ortaya koymaktadır.

Şekil-2 ile 7 arasında, elde edilen modellere ait ROC grafikleri gösterilmektedir. YOLOv8 modeli ile ulaşılan sonuçlar, sınıflar arasında yüksek bir ayrılabilirlik düzeyi olduğunu açıkça ortaya koymakta; bu da modelin temel görsel örüntüleri başarıyla öğrendiğini kanıtlamaktadır. Şekil-12'de yer alan hata matrisinde görüldüğü üzere model, tüm emisyon sınıflarında %96 ile %98 arasında değişen yüksek doğruluk oranlarına ulaşmıştır. Bu yüksek başarı, büyük ölçüde YOLOv8'in karmaşık yapıları olağanüstü bir hassasiyetle algılayabilen gelişmiş mimarisinden kaynaklanmaktadır. Modelin sahip olduğu derin evrimsel katmanlar, daha etkili kenar ve desen çıkarımı yaparak sınıflar arasındaki ince farkların ayırt edilmesine olanak tanımakta ve bu durum üstün sınıflandırma başarısına doğrudan katkı sağlamaktadır. Ayrıca Şekil-13'teki hata matrisi ile kıyaslandığında, YOLOv8'in hem genel doğruluk hem de sınıfları birbirinden ayırt etme noktasında baz modeli önemli ölçüde geride bıraktığı görülmektedir. YOLOv8'in sınıflar arası karışıklığı azalttığı ve genel başarı oranını ciddi oranda artırdığı saptanmıştır. Modelin bu başarısındaki diğer kritik unsurlar ise eğitim sürecinde kullanılan CloU kayıp fonksiyonu ve optimize edilmiş çapa içermeyen algılama yaklaşımıdır. Tüm bu faktörler, YOLOv8'in nesne algılama ve sınıflandırma görevlerinde yüksek güvenilirlik sunduğunu ve uygulama düzeyinde kullanıma hazır bir yapıda olduğunu göstermektedir.

4.4. Tartışma

Görüntü işleme alanında sıklıkla tercih edilen YOLO algoritması; çapa içermeyen yaklaşımı, ayrıştırılmış başlık yapısı [27] ve güçlü özellik çıkarma katmanları sayesinde yüksek doğrulukta sonuçlar üretmektedir. Bu mimari; kesinlik, duyarlılık, F1 skoru ve doğruluk (ACC) ölçülerinde yüksek başarı elde edilmesini kolaylaştırmaktadır. Model başarısı genel olarak sahip olduğu katman yapısına ve mimari bütünlüğüne bağlıdır. Bu bağlamda Xception, derin ve parametrik mimarisıyla görüntü işleme ve paylaşımlı öğrenme senaryolarında güçlü bir alternatif olarak öne çıkmaktadır. Başarımı YOLOv8'in bir miktar altında kalsa da CNN mimarisinden daha yüksek değerlere ulaşmıştır. Temel CNN modeli ise sınırlı katman sayısı ve düşük parametre kapasitesi nedeniyle karmaşık görüntü özelliklerini yakalamada yetersiz kalmıştır. Bu üç algoritmanın genel bir karşılaştırması, YOLO'nun bir nesne tanıma algoritması olduğunu; Xception ve CNN'in ise nesne sınıflandırması için daha uygun olduğunu



göstermektedir. Bu durum başarımların değerlerini şu şekilde etkilemektedir: Nesne sınıflandırma algoritmaları olan CNN ve Xception, modele beslenen görüntünün tamamını analiz ederek bir sonuç üretir. Buna karşın YOLO, görüntünün bütününe odaklanmak yerine doğrudan nesnenin kendisini tanımlayarak sınıflandırma yapar. Diğer bir ifadeyle, görüntü içerisinde farklı nesne sınıfları bulunsu dahi YOLO her bir nesneyi bağımsız olarak tanımlayabilir ve birden fazla sonuç üretebilir. Özetle model, nesneleri eğitildiği verilerle olan benzerliklerine göre kontrol ederek sınıflandırmaktadır.

4.5. Geliştiren Yazılım

Bu çalışma, yalnızca modellerin başarımlarını sunmakla kalmamış; aynı zamanda en yüksek başarı oranına sahip olan YOLOv8 yapay zeka algoritmasının entegre edildiği, mobil cihazlarda çalışabilen bir yazılım geliştirmiştir. Etiketleme ortamı olarak Roboflow kullanılmış, YOLO modelinin eğitilmiş API'si sisteme dahil edilmiş ve modelin görüntü tahmin

Şekil-14: Uygulama Arayüzü

çıktıları uygulamaya JSON formatında aktarılmıştır. Kullanıcı arayüzü (UI) ve kullanıcı deneyimi (UX) tasarımı açısından kolaylık sağlaması amacıyla tek ekran üzerinde çalışan yazılım; kullanıcılar bir görüntü seçip banknot detaylarını girdikten sonra, ilgili görseldeki kağıt parayı otomatik olarak tanımaktadır. Şekil -4'te, geliştirilen yazılımın uygulama arayüzü gösterilmektedir.

5. Sonuç

Görüntü algılama algoritmaları, nesne algılama süreçlerinde devrim niteliğinde bir yaklaşım sunmaktadır. Gerçek zamanlı nesne algılama amacıyla tasarlanan bu algoritmalar, görüntüler üzerinden nesne tanıma işlemlerinde sergiledikleri

yüksek hız ve hassasiyet oranlarıyla öne çıkmaktadır. Bu çalışma, Türkiye Cumhuriyeti'nin ilk beş emisyonuna ait banknot görüntülerine odaklanmıştır; veri kazıma yöntemiyle özgün bir veri kümesi oluşturmuştur. Elde edilen bu veri kümesi; CNN, YOLOv8 ve Xception derin öğrenme algoritmaları kullanılarak eğitilmiştir. Analizler sonucunda, YOLOv8 algoritması ile eğitilen modelin 0,94 doğruluk oranıyla en başarılı sonucu verdiği kanıtlanmıştır. Ayrıca bu çalışma, yalnızca model eğitimiyle sınırlı kalmamış; geliştirilen modeli bir mobil yazılıma entegre ederek koleksiyonerlerin ve nümismatik meraklılarının hizmetine sunmuştur. Bu uygulama sayesinde kullanıcılar, çektikleri banknot fotoğraflarını yükleyerek emisyon bazlı otomatik sınıflandırma yapabilmektedir. Test sonuçları, YOLOv8 algoritmasının, karşılaştırma amacıyla kullanılan CNN ve Xception algoritmalarına kıyasla belirgin şekilde daha yüksek bir sınıflandırma başarımı sergilediğini ortaya koymuştur. Bu üstünlüğün; YOLOv8'in çapa içermeyen yaklaşımından, ayrıştırılmış başlık yapısından ve görüntünün tamamını analiz etmek yerine doğrudan nesne odaklı tanımlama yapmasından kaynaklandığı değerlendirilmektedir. Gelecekteki çalışmalar kapsamında mevcut yazılımın, daha fazla ülkeye ait tarihi banknotları ve madeni paraları tanıyacak şekilde genişletilmesi planlanmaktadır. Literatür incelendiğinde, banknot tanıma üzerine yapılan yapay zeka çalışmalarının genellikle güncel tedavüldeki paralara odaklandığı görülmektedir. Bu çalışma ise eski banknot koleksiyoncularına yönelik bir mobil uygulama geliştirerek literatürdeki bu boşluğu doldurmaktadır. Çalışma aynı zamanda; sanat, mimari ve sosyal yönlerden ait oldukları dönemin izlerini taşıyan tarihi mirasın dijital ortamda tanımlanması ve gelecek nesillere aktarılmasında kritik bir rol üstlenmektedir. Sonuç olarak bu araştırma, elde edilen yüksek sınıflandırma başarısıyla, tarihi dokümanların dijital olarak tanınmasında derin öğrenme teknolojilerinin sahip olduğu büyük potansiyeli bir kez daha kanıtlamıştır.

Kaynakça

- [1] Aydın, C., Özdemirci, F. *Elektronik Belgelerin Arşivlenmesinde Gerçekliğin ve Bütünlüğün Korunması*, Bilgi Dünyası, 2011, pp. 105-127.
- [2] Çetin, M. *Türkiye Cumhuriyet Merkez Bankası (TCMB) Para Politikası Uygulamalarının Gelişimi*, Finansal Araştırmalar ve Çalışmalar Dergisi, 2016, pp. 67-101.
- [3] Aksoy, B., Korucu, K., Çalışkan, Ö., Osmanbey, Ş., & Halis, H. D. (2021). *İnsansız Hava Aracı ile Görüntü İşleme ve Yapay Zekâ Teknikleri Kullanılarak Yangın Tespiti: Örnek Bir Uygulama*. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 2021, 9(6), pp. 112-122.
- [4] Özdet, B., & İçer, S. *Akciğer bilgisayarlı tomografi görüntülerinde görüntü işleme uygulamaları ile tümörlerinin tespit edilmesi*. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 2022, 27(1), pp. 135-150
- [5] Idem, A., Eldem, H., & Palalı, A. *Görüntü işleme teknikleriyle yüz algılama sistemi geliştirme*. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 2017, 6(2), pp. 44-48
- [6] Üncü, I. S., Kayakuş, M., Yavru, A. C., İbadov, N. *Binalarda Çatlak Kontrolünde CNN Tabanlı Görüntü İşleme Ölçüm Sisteminin Kullanılması*, Gazi Journal of Engineering Sciences, 2023, pp. 257-267.
- [7] Karasulu, B., Yücalar, F., Borandağ, E. *İnsan Kulağı Görüntüleri Kullanarak Cinsiyet Tanıma İçin Derin Öğrenmeye Dayalı Hibrit Yaklaşım*, Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi, 2022, s. 1579-1594.
- [8] Kıran, E., Karasulu, B., & Borandağ, E. *Gemi Çeşitlerinin Derin Öğrenme Tabanlı Sınıflandırılmasında Farklı Ölçeklerdeki Görüntülerin Kullanımı*, Journal of Intelligent Systems, Theory and Applications, 2022, pp. 161-167.
- [9] Şahin, Ö. *iOS platformunda görme engelliler için TL tanıma uygulaması*, Selçuk Üniversitesi, Yayınlanmış yüksek lisans tezi, Konya, 2017, pp. 72.
- [10] Baykal, G., Demir, Uğur., Shyti, Ira., Ünal, G. *Derin konvolüsyon sinir ağları kullanılarak Türk lirası banknotları sınıflandırması*, 2018 26. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU), İzmir, Türkiye, 2018, s. 1-4.
- [11] Gençal, M. C. *SURF Yöntemi Kullanarak Türk Madeni Paralarını Tanıma*, 4th International Mediterranean Scientific Research Congress, Nicosia, Cyprus, 2023
- [12] Yeşiltepe, M., Elkiran, H., Rasheed, J. *Türk Lirası Banknotlarının Transfer Öğrenme ve Derin Öğrenme Kullanılarak Sınıflandırması*, Acta Infologica, 2024, 8(2), ss. 133-156.
- [13] Makaklı, E., Ozar, B. *Banknot tasarımında mimari imgeler ve değerler: Türk Cumhuriyeti E1. Emisyon Grubu 1*, GU Journal of Science, Bölüm B: Sanat, Beşeri Bilimler, Tasarım ve Planlama, 2024, 12(4), ss. 607-617.
- [14] Özgür, K., Ballı, S. *Görme Engelliler İçin Görüntü İşleme Tabanlı Bir Para Tanıma Uygulaması Geliştirilmesi*, IV International Conference on Data Science and Applications, Turkey, 2021.
- [15] Lo, W. W., Yang, X., Wang, Y. *Bir Xception Konvolüsyon Sinir Ağı için Kötü Amaçlı Yazılım Sınıflandırması ve Transfer Öğrenimi*, 2019 10. IFIP Uluslararası Yeni Teknolojiler, Hareketlilik ve Güvenlik Konferansı (NTMS), 2019, s. 1-5.
- [16] Hussain, M. *YOLO-v1'den YOLO-v8'e, YOLO'nun Yükselişi ve Dijital Üretim ile Endüstriyel Kusur Tespitine Yönelik Tamamlayıcı Doğası*, Machines, 2023, s. 677.
- [17] Chollet, F. *Xception: Derin öğrenme, derinlik açısından ayrılabilir konvolüsyonlarla*, IEEE Bilgisayar Görüşü ve Pattern Tanıma Konferansı Bildirileri, 2017, s. 1251-1258.
- [18] Yamashita, R., Nishio, M., Do, R.K.G. *Konvolüsyon sinir ağları: radyolojide genel bakış ve uygulama*, Görüntüleme İçeriği, 2018, 9, s. 611-629.
- [19] Gordon, E., Loaiza-Ganem, G., Pleiss, G., Cunningham, J. P. *Çapraz Entropi Kaybının Kullanımları ve Kötüye Kullanımları*, Modern Derin Öğrenmede Vaka Çalışmaları, 2020, s. 11.
- [20] Liu, J., Liu, X., Chen, H., & Luo, S. *MDD-YOLOv8: Sentetik Apertürlü Radar Görüntüleri için YOLOv8 Tabanlı Çok Ölçekli Nesne Tespit Modeli*, Applied Sciences, 2025, s. 2239.
- [21] Abodayeh, A., Alotaibi, A., Alsalamah, S. *Veri Analitiği İçin Web Kazıma: Güzel Bir Çorba Uygulaması*, 2023 Altıncı Uluslararası Veri Bilimi Konferansı, Prince Sultan Üniversitesi (WiDS PSU), IEEE, 2023, s. 68.
- [22] Abodayeh, A., Hejazi, R., Najjar, W., Shihadeh, L., & Latif, R. *Veri analitiği için web kazıma: Güzel bir çorba uygulaması*. 2023 yılında Prince Sultan Üniversitesi'nde (WiDS PSU) altıncı uluslararası veri bilimi konferansı, IEEE, 2023, s. 65-69.
- [23] Raksa, A. R. A., Padukawan, F., Aji, K. K., Alamsyah, M. R.,

- Octaviyani, S. & Laksana, E. A. *Derin Öğrenme ve Seyrek Kategorik Krosentropi Kaybı Fonksiyonu Kullanılarak Duvar Takip Robot Navigasyonu Sınıflandırması*, Orta Asya ve Kafkasya, 2022, 23(1), ss, 5175-5182.
- [24] Ruby, U., Yendapalli, V. *İkili çapraz entropi ile Görüntü Sınıflandırması için Derin Öğrenme Tekniği*, Int. J. Adv. Trends Comput. Sci. Eng., 2020, ss. 5393-5397.
- [25] Du, S., Zhang, B., Zhang, P., Xiang, P. *Çok Ölçekli Nesne Tespiti İçin CIOU Kaybına Dayalı Geliştirilmiş Sınırlı Kutu Regresyon Kaybı Fonksiyonu*, IEEE 2. Uluslararası Desen Tanıma ve Makine Öğrenimi Konferansı (PRML), 2021, s. 92–98.
- [26] Wu, J. *Konvolüsyon Sinir Ağlarına Giriş*, Yeni Yazılım Teknolojisi Ulusal Anahtar Laboratuvarı, Nanjing Üniversitesi, Çin, 2017, s. 495.
- [27] Liu, J., Zhang, C., Li, J. *Yüzey Kusurlarını Tespit Etmek İçin Çapasız Nesne Detektörlerinin Kullanımı*, Süreçler, 2024, s. 2817.