



Üç Aşamalı Derin Öğrenme Tabanlı Otomatik Araç Plakası Algılama ve Tanıma Sistemi

Autonomous Vehicle License Plate Detection and Identification System Based on Three-Stage Deep Learning

Emre Yücel¹ , Yalçın İşler^{1,2,*} , Yakup Kutlu³ 

¹İskenderun Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İskenderun, Hatay, Türkiye

²İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Biyomedikal Mühendisliği Bölümü, Çiğli, İzmir, Türkiye

³İskenderun Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İskenderun, Hatay, Türkiye

Öz

Araç plakalarının otomatik olarak algılanması ve tanımlanması sistemleri araçlarla girilebilen ve güvenlik gerektiren ücretli otopark girişleri, otoban gişeleri, mobese kameraları, site ve alış-veriş merkezi girişleri gibi yerlerde vazgeçilmez hale gelmiştir. Araç sayısının hızlı artışı nedeniyle, araç plakalarının hızlı ve doğru tespit edilmesini gerektirmektedir. Öte yandan görüntüleme cihazına araçların ve plakaların farklı açı ve boyutlarda gelmesi nedeniyle araç plakasının otomatik tanınmasında problem yaşanmaktadır. Bu çalışmada You Only Look Once (bu yaygın İngilizce tanımına uygun yaygın kısaltması olan YOLO) ve evrimsel sinir ağı (ESA) derin öğrenme modelleri ile araç plakasının algılanması, araç plakası üzerindeki karakterlerin yerlerinin tespit edilmesi ve bu karakterlerin sınıflandırılarak plakanın tanınması için üç aşamalı bir sistem tasarlanmıştır. Plakaların bulunması ve plaka üzerindeki karakterlerin ayrıştırılması aşamalarında kullanılan iki ayrı YOLO modelinin her ikisinde de %100 başarı elde edilmiştir. Plaka üzerindeki karakterlerin sınıflandırılması ile plaka tanıma aşamasında kullanılan ayrı bir ESA modelinde ise %94.9 başarı oranı elde edilmiştir. Literatürle kıyaslandığında, ilk iki aşamada elde edilen sonuçların diğer çalışmalardan daha yüksek olduğu ve son aşamada ise yaklaşık olarak benzer başarı elde edildiği görülmüştür.


Anahtar Kelimeler: ESA, derin öğrenme, otomatik araç plakası algılama, otomatik araç plakası tanıma, YOLO.


Abstract


Autonomous detection and identification of vehicle license plates have become indispensable in places that can be entered by vehicles and require security, such as paid parking exits, highway toll kiosks, mobile security cameras, site and shopping centre entrances. Due to the rapid increase in the number of vehicles, it is necessary to detect vehicle license plates quickly and accurately. On the other hand, the main problem in automatic recognition of vehicle license plates is that vehicles and license plates come to the imaging device at different angles and sizes. In this study, a three-stage system was designed to detect the license plate using You Only Look Once (YOLO) and Convolutional Neural Network (CNN) deep learning models, to locate the characters on the license plate, and to classify these characters and identify the license plate. 100% success was achieved in both stages of finding the license plates and separating the characters on the license plate using two distinct YOLO models. A success rate of 94.9% was achieved in the license plate recognition phase by classifying the characters on the license plate using a separate CNN model. When compared with the literature, the first two stages achieved higher accuracies than the other studies and the last stage resulted in similar accuracy.

Keywords: CNN, deep learning, automatic vehicle plate detection, automatic vehicle license recognition, YOLO.

*Sorumlu yazarın e-posta adresi: islerya@yahoo.com

Emre Yücel  orcid.org/0009-0009-7617-8087

Yalçın İşler  orcid.org/0000-0002-2150-4756

Yakup Kutlu  orcid.org/0000-0002-9853-2878



1. Giriş

Son yıllarda araç kullanım sayısı insanların ihtiyaçları ve nüfusun çoğalmasından dolayı hızla artmıştır. Türkiye İstatistik Kurumu'na göre son 20 yılda sadece ülkemizde kayıtlı araç sayısı yaklaşık dört katına çıkmıştır (TÜİK, 2024). Araç sayısındaki bu artış yarattığı trafik yoğunluğunun yanısıra park alanları, otoyol ve köprü gişeleri gibi ücret tahsilatı noktaları ile radara yakalanan ve suça karışan araçların tespit edilmesinde sorunlarına artışına sebep olmuştur (Du vd. 2017).

Bu sorunları çözmek için araç plakalarının otomatik olarak tanımlanması bir seçenek olabilir (Özby ve Erçelebi 2005). Otomatik araç plaka sistemleri insan bir operatöre ihtiyaç duyulmadan, araç plakalarının doğru bir şekilde tanımlanmasını amaçlamaktadır (Du vd. 2017). Temelde otomatik plaka tanıma sistemi üç temel aşamadan oluşur: (1) plaka yerinin tespiti, (2) bulunan plakadaki karakterlerinin ayrıştırılması ve (3) bu ayrıştırılan karakterlerin sınıflandırılması (Du vd. 2017).

İlk yapılan araç plaka tanıma sistemlerinin çoğunlukla görüntü işleme teknikleri kullanılmıştır (Zhuang vd. 2018). Zamanla teknolojinin gelişmesiyle birlikte, makine öğrenme algoritmalarının kullanımı her alanda artmıştır (İşler 2009). Son zamanlarda görüntü tabanlı makine öğrenmesi çalışmalarında derin öğrenme (özellikle de evrimsel sinir ağı (ESA) modellerinin kullanımı oldukça popüler hale gelmiştir (Narin ve İşler 2021). Böylece görüntü işleme algoritmalarına ve herhangi bir ön işleme gerek olmadan daha hızlı bir sonuç elde edilmesine olanak sağlanmaktadır (Sürücü vd. 2021).

Son zamanlarda yapılan araç plaka tanıma sistemi çalışmalarına bakıldığında, görüntü işleme teknikleri ile ESA sinir ağı modelleri birlikte kullanılmaya başlandığı görülmektedir (Çay vd. 2023). Örneğin, Anagnostopoulos ve arkadaşları yaptıkları çalışmada 1334 araçlık bir veri seti kullanmışlardır. Plakadaki özellik çıkarımı için kayan ortak merkezli pencereler ve bağlı bileşen analizi, karakterlerin tanınması ve sınıflandırılması için olasılıksal sinir ağları kullanarak %89.1 sınıflandırıcı doğruluğu oranı elde etmişlerdir (Anagnostopoulos vd. 2006). Zhou ve arkadaşları yaptıkları çalışmada 410 araçlık kendi oluşturdukları ve 112 araçlık Caltech Cars veri setlerini kullanmışlardır. Bu çalışmada kelime eşleme ve Scale Invariant Feature Transform (SIFT) algoritmaları kullanılarak %93.2 sınıflandırıcı doğruluğu elde edilmiştir (Zhou vd. 2012). Laroca ve arkadaşları da yaptıkları çalışmada You Only Look Once (YOLO) derin öğrenme mode-

li kullanarak %93.5 sınıflandırıcı doğruluğu elde etmişlerdir (Laroca vd. 2018). Shashidhar ve arkadaşları ise Hint Karakterli plakalarını otomatik tanımlamayı amaçlamışlardır. Bu çalışmada plakanın yeri YOLO modeli ile bulunduktan sonra karakterlerin tanınması için geliştirdikleri bir ESA modelini görüntü iyileştirme metotları ile desteklemişlerdir. Bu ilginç çalışmada, araç plaka yerinin tespiti için 1200 ve karakterlerin tanımlanması için 6439 farklı Hint alfanümerik görüntü veri kümesi kullanılmıştır. Sonuç olarak %91.5 sınıflandırıcı doğruluğuna ulaşmayı başarmışlardır (Shashidhar vd. 2021). Guo ve Liu ise plaka yerinin tespiti ve karakterinin tanınmasını amaçladıkları çalışmada 332 farklı araç görüntüsü kullanmışlardır. Plakanın tanınması için renk özellikleri ve Hough Dönüşümü kullanılmış olup %93.6 sınıflandırıcı doğruluğunu elde edilmiştir (Guo ve Liu 2008). Yuan ve arkadaşları ise plaka tespiti için 3828 araçlık Caltech veri seti kullanmışlardır. Plakadaki özellik çıkarımı ve plaka yerinin tespiti için kenar bulma, bölütleme ve çizgi yoğunluk filtreleri kullanılmışlardır. Yazarlar sınıflandırıcı olarak destek vektör makinesi (DVM) kullandıkları çalışmada %96.6 doğruluk elde etmişlerdir (Yuan vd. 2016). Li ve arkadaşları da plaka tespiti için elde edilen görüntünün çözünürlüğüne ve gece-gündüz oluşuna göre dört gruba ayrılmış toplam 1418 araçlık bir veri seti kullanmışlardır. Plaka tespiti için kenar bulma, geometrik görsel öznelik çıkarma yöntemlerini kullanarak %97.6 başarı elde edilmiştir (Li vd. 2013). Panahi ve Gholampour tarafından gerçekleştirilen çalışmada ise plaka yerini ve numaralarını tanımak amaçlanmıştır. Bunun için kendi oluşturdukları 8000 araçlık veri seti kullanmışlardır. Plakadan öznelik çıkarımı için bağlı bileşenler analizi ve rastgele örnekleme yöntemlerini kullanmışlardır. Sınıflandırıcı olarak olasılıksal DVM kullandıkları çalışmada %91.4 başarı elde edilmiştir (Panahi ve Gholampour 2016). Rafique ve arkadaşları ise ESA kullanarak plaka yerini bulmayı amaçlamışlardır. Bunun için Pascal VOC2007 veri seti ile kendi oluşturdukları toplamda 2871 görsellik veri seti kullanmışlardır. Plakadaki yerinin tespiti için bölge tabanlı ESA (R-ESA) derin öğrenme modeli ve DVM algoritmaları kullanılan bu çalışmada %94.5 sınıflandırıcı doğruluğu elde edilmiştir (Rafique vd. 2018). Li ve arkadaşları tarafından gerçekleştirilen başka bir çalışmada plaka algılama ve tanıma amaçlanmıştır. Bunun için 322000 eğitim, 138000 test için olmak üzere toplam 460000 görsellik bir veri seti kullanmışlardır. Plakayı algılamak ve tanımak için ESA ve R-ESA modelleri kullanılmış ve %96.5 sınıflandırıcı doğruluğu elde edilmiştir (Li vd. 2018). Telatar ve Çamaşcıoğlu (2007) plaka algılamayı ve tanımayı amaçlamışlardır. Bunun için 100 araçlık veri seti

kullanılmışlardır. Plaka yerinin tespiti için renk değişimi kullanılmıştır. Plakadaki karakter tespiti için yapay sinir ağı (YSA) modeli kullanılmıştır. Yapılan çalışma sonrası %98.8 başarı oranı elde edilmiştir. Zhuang ve arkadaşları yaptıkları çalışmada plaka tanıma amaçlı AOLP 1874 araçlık, Media Lab 706 araçlık, Chinese License 5057 araçlık veri setlerini kullanmışlardır. Plakayı tanıma için DeeplabV2 Resnet 101 modellerini kullanarak %99.2 başarı oranı elde edilmiştir (Zhuang vd. 2018). Plaka tanımayı amaçlayan başka bir çalışmada, plaka tespiti için 300 eğitim ve 130 test verisinden oluşan araç veri seti ve karakter tanımak için 2165 eğitim verisinden ve 975 test verisinden oluşan karakter veri seti kullanılmışlardır. Bu çalışmada plakalar manuel olarak etiketlenmiştir. Sınıflandırma için Resnet-101 modeli kullanılarak %98.4 sınıflandırıcı doğruluğu elde edilmiştir (Bayram 2020). Bingöl ve Kuşçu (2008) yaptıkları çalışmada plaka tanımayı amaçlamışlardır. Bunun için 100 görüntüden oluşan veri seti kullanmışlardır. Plakadan öznitelik çıkarımı ve yer tespiti için görüntü işleme algoritmaları kullanmışlardır. Karakter tespiti için ise karakter bulup veri tabanı ile karşılaştırılmıştır. Yapılan çalışma sonrası %87.0 başarı oranı elde edilmiştir. Çelik ve Oral (2003) yaptıkları çalışmada plaka tanımayı amaçlamışlardır. Bunun için 105 görsellik veri seti üzerinden görüntü işleme algoritmaları ile plaka yeri tespiti yapılmıştır. Plakadaki karakter tespiti için YSA modeli kullanılmış olup %89.0 sınıflandırıcı doğruluğu elde edilmiştir.

Araç sayısının ve trafik yoğunluğunun hızlı artışı nedeniyle, araç plakalarının hızlı ve doğru tespit edilebilmesi için yukarıda açıklandığı gibi birçok çalışma yapılmıştır. Öte yandan görüntüleme cihazına araçların farklı açılarda girmesi ve plakaların farklı boyutlarda ve yerlerde olması nedeniyle araç plakasının otomatik tanınmasında problem yaşanmaktadır. Bu problemleri aşmak için, bu çalışmada hem görüntü kalitesini artırmak için görüntü işleme yöntemlerini hem son yıllarda umut vaat eden başarılı sonuçları nedeniyle YOLO ve ESA tabanlı derin öğrenme modelleri kullanılarak otomatik bir plaka tanıma sistemi geliştirilmesi hedeflenmiştir. Bu hedefe ulaşmak için plaka yerinin bulunması, plaka üzerindeki karakterlerin belirlenmesi ve bu karakterlerin tanınması şeklinde üç aşamalı bir sistem önerilmiştir. Problemin tanımlandığı ve literatürde verilen çözüm önerilerinin özetlendiği bu giriş bölümünden sonra makalenin akışı şu şekilde olacaktır. Önce çalışmada kullanılan veri setinin de açıklandığı *Gereç ve Yöntemler* bölümü, sonra çalışmanın nasıl gerçekleştirildiğinin verildiği *Uygulama* bölümü, son olarak ise elde edilen sonuçlar ve bu sonuçların literatürdeki yerlerinin yorumlandığı *Sonuçlar ve Tartışma* bölümü verilecektir.

2. Gereç ve Yöntemler

2.1. Veri Setleri

Plaka yerinin tespiti, karakterlerin ayrıştırılması ve karakterlerin sınıflandırılması olacak şekilde üç aşamalı bir sistem geliştirilecek olması sebebiyle modellerin eğitilmesi için üç farklı veri seti kullanılmıştır. İlk aşama olan araç görseli üzerindeki plaka yerinin tespiti için internet üzerinden kolayca erişilebilen Kaggle Car License Plate Detection Dataset veri seti kullanılmıştır. Bu veri seti içerisinde, farklı ülkelerdeki farklı marka, model ve renklerde toplanmış toplam 433 araç fotoğrafı bulunmaktadır. Bu araçlara ait plakaların konumları eğitim için ayrı ayrı belirlenmiş ve bu konumlar veri setine ait XML dosyası içerisinde kaydedilmiştir. Bu veri setinden örnek araç görüntüleri Şekil 1'de gösterilmiştir (Larxel 2020).

İkinci aşama olan plakada yer alan karakterlerin konumlarının belirlenmesi için farklı bir veri seti oluşturulmuştur. Bu veri seti internet üzerinden görsel arama motorları ile araştırma yapılarak uygun olanların toplandığı farklı plakalardan oluşan yeni bir veri setidir. Bu veri seti içerisinde toplamda 451 araç plaka görseli ve her görselde 6 karakter bulunmaktadır. Bu plakalara ait karakterlerin konumları eğitim için ayrı ayrı belirlenmiş ve bu konumlar veri setine ait XML dosyası içerisinde kaydedilmiştir.

Son aşama olan plakada yer alan karakterleri sınıflandırmak için, yine internet üzerinden kolayca erişilebilen Kaggle License Plate Digits Classification Dataset veri seti kullanılmıştır (Jelal 2021). Toplamda 35 kategoride 35500 karakter görseli yer almaktadır. Her karakter için kullanılan görsellerin örnek görüntüsü Şekil 2'de gösterilmiştir.



Şekil 1. Plaka yerinin tespiti için eğitimde kullanılan örnek araç görselleri (Larxel 2020).



Şekil 2. Karakter tanıma için eğitimde kullanılan örnek karakter görselleri (Jelal 2021).

Çalışmanın test edilebilmesi için eğitimde kullanılmamış veriler olması gerektiğinden, sadece test aşaması için yeni bir veri seti oluşturulmuştur. Bu veri seti internet üzerinden görsel arama motorları kullanılarak birbirinden farklı renk, ortam, model, marka ve açılarda konumlanmış toplam 125 araç ile oluşturulmuştur. Bu araçların plakalarında bulunan toplam karakter sayısı ise 922'dir.

2.2. YOLO Algoritması

YOLO (You Look Only Once) “sadece bir kere bak” demektir ve son zamanlarda ortaya çıkmış, nesne tespitinde kullanılan bir algoritma olup gerçek zamanlı görüntü işleme için kullanılan bir nesne algılama sistemidir. YOLO algoritması görselleri öncelikle bölgelere ayırır ve her bir bölgede nesne olup olmadığını incelemektedir. Algoritma bunu yaparken bölgelerdeki nesnelere güven oranı tayin ederek bu güven oranına göre nesnenin ne olduğuna karar vermektedir. YOLO giriş görüntülerini SxS ızgara hücrelerine bölmektedir (Redmon vd. 2016). Her bir ızgara hücrei yalnızca bir nesneyi ve sabit sayıda sınır kutusu tahmin etmektedir (Çağıl ve Yıldırım 2020). YOLO algoritması görüntüleri yaklaşık 40-90 fps (saniye başına kare) hızında işleyebildiğinden diğer yöntemlere göre oldukça hızlıdır. Böylece bir videonun gerçek zamanlı olarak (sadece birkaç milisaniye gecikme ile) işlenebilmesini mümkün kılmaktadır (Shinde vd. 2018).

R-ESA gibi yöntemler de görüntüleri bölgelere ayırıyor olmasına rağmen, YOLO bu bölgeleri tek nöral ağdan geçirirken diğerleri her blok için ayrı nöral ağlar kullandıkları için, YOLO daha hızlı ve etkili çalışabilmektedir (Bilgin 2021). YOLO algoritması da zaman içerisinde güncellenerek geliştirilmeye devam etmekte ve sürüm olarak (YOLOv3, YOLO algoritması sürüm 3 gibi) yayınlanmaktadır. Bu çalışmada YOLOv3 sürümü kullanılmıştır. Bu sürümünde 53


katmanlı ESA yapısı kullanan DarkNet-53 mimarisine 53 katman daha ilave edilerek toplam 106 katmanlı ESA derin öğrenme yapısına ulaşılmıştır. YOLOv3 bir önceki sürümüne göre daha yavaş çalışsa da, artı bloklar, bağlantı atlama ve yukarı örnekleme gibi özellikler de bu yapıya eklenmiştir.

2.3. Resim İyileştirme Ön İşlemleri

Plaka üzerindeki karakterler ayrıştırıldıktan sonra hem ESA eğitim aşamasında hem de karakterlerin sınıflandırılması işleminde daha doğru sonuç elde edebilmek için karakter görsellerine görüntü iyileştirme yöntemlerinden sırasıyla eşikleme ve histogram eşitleme uygulanmıştır.

Eşikleme


Eşikleme, bir görüntüdeki her bir piksel renk değerinin belirlenmiş olan eşik değerine göre değiştirilme işlemidir. Yani eğer piksel renk değeri belirlenen eşik değerinden küçükse o piksel renk değerine siyah atanır. Bu çalışmada görüntüdeki piksellerin ortalama değeri eşik değer olarak alınmıştır. Örnek bir araç plakasından alınan karakter görseline eşikleme uygulanması sonucu oluşan yeni görüntü Şekil 3'de gösterilmiştir.



Şekil 3. Orijinal görüntüye eşikleme uygulanması.

Histogram Eşitleme

Görüntüde histogram, bir resimdeki renk değerlerinin sayılarını gösteren grafikdir (Gonzalez ve Woods 2007). Histogram eşitleme ise bir görüntüdeki renk değerlerinin belirli bir değer aralığı içerisinde kümelenmesinden kaynaklı renk bozukluğunu gidermek için kullanılan bir yöntemdir. Hesaplama zamanı düşük ve oldukça etkili sonuçlar üretebilen bir yöntemdir (Arisoy ve Dikmen 2014). Bu yöntem sayesinde görüntüdeki renk değerleri belirli bir aralığa dağıtıldığından dolayı görüntüdeki ayrıntılara ve özneliklere daha kolay erişilebilmektedir. Plakalardan elde edilen karakter görüntülerinin, eşikleme ve histogram eşitleme sonrası oluşan yeni görüntüleri Şekil 4'de örnek olarak gösterilmiştir.



Şekil 4. Orijinal karakter ve görüntüsünün, görüntü iyileştirme sonrası çıktıları.

2.4. ESA Modeli

ESA, genellikle görüntü işlemede kullanılan, girdi olarak görselleri alan ve otomatik olarak görüntüleri işleyen bir derin öğrenme algoritmasıdır (Sürücü 2022a, Sürücü 2022b, Narin ve İşler 2021). Farklı işlemler ile görsellerdeki özellikleri bulan ve bulunduğu özellikler sayesinde görselleri sınıflandıran ESA algoritması farklı katmanlardan oluşmaktadır: Konvolüsyon katmanı, Havuzlama katmanı ve Tam Bağlantılı Sınıflandırma katmanı. ESA modeli yaygın kullanılan bir derin öğrenme modeli olup ayrıntılı bilgiye kitaplardan erişilebilir (Chollet 2018).

2.5. Metodoloji

İlk aşama olan araç üzerindeki plaka yerlerinin tespiti için YOLO ile eğitilmiş model kullanılarak araç üzerindeki plakanın konumu belirlenmiştir. Daha sonra resim kesme yöntemi ile plaka araç görselinden ayrıştırılmıştır. Şekil 5'de plakası bulunmuş ve işaretlenmiş araç görseli gösterilmiştir.

Daha sonra, plaka üzerindeki karakterlerin yerlerinin tespiti için YOLO ile eğitilmiş model kullanılmıştır. Böylece plaka üzerindeki karakterlerin konumları belirlenmiş ve karakterler resim kesme yöntemi plaka görselinden ayrıştırılmıştır.



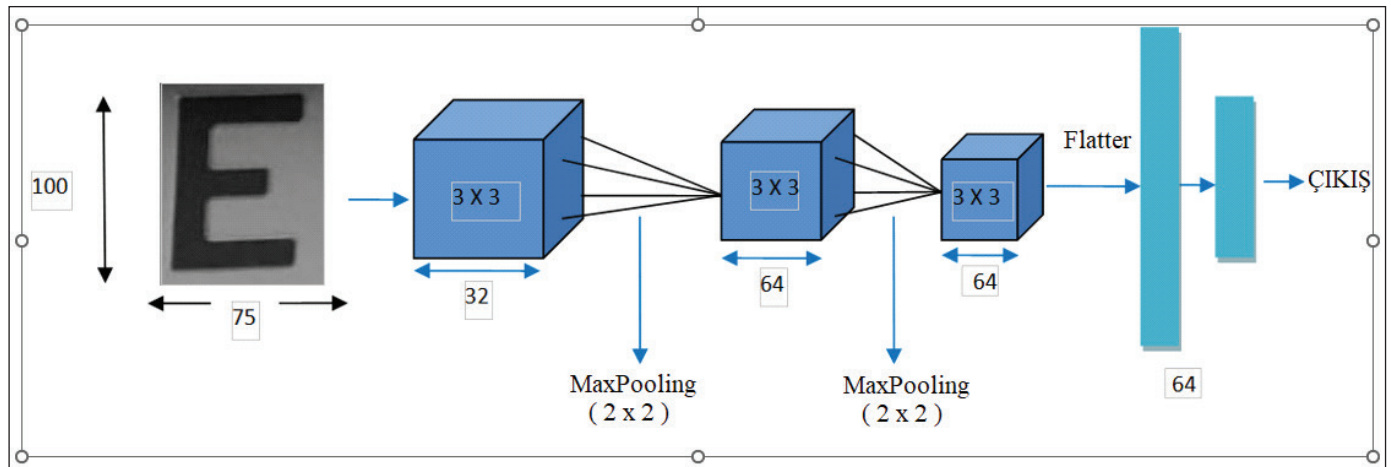
Şekil 5. YOLO algoritması ile plakası bulunmuş ve işaretlenmiş araç görseli.



Şekil 6. YOLO algoritması ile karakterleri işaretlenmiş plaka görseli.

Şekil 6'da plaka üzerindeki karakterlerin YOLO modeli işaretlenmesi sonucu oluşan görsel gösterilmiştir.

Karakterin sınıflandırılması için ESA modeli kullanılmıştır. Eğitim için eğitim görselleri 75x100 boyutlarına getirilmiştir. Modelimizin konvolüsyon katmanları sırasıyla, 3x3'lük 32 filtreden, ardından 2x2'lik MaxPooling katmanından, 3x3'lük 64 filtreden, ardından 2x2'lik MaxPooling katmanından ve 3x3'lük 64 filtreden oluşmakta, fully connected katmanı ise 64 nörondan oluşan tek gizli katmanından oluşmaktadır. Epoch değeri 10, batch_size değeri ise 64'tür. Eğitilen ESA modeli ile ayrıştırılan karakter görsellerin üzerinde yer alan karakterlerin sınıflandırılması sağlanmıştır. Oluşturulan ESA modeli katmanlarının ve parametrelerinin de yer aldığı hali ile Şekil 7'de görselleştirilmiştir.



Şekil 7. Oluşturulan ESA modelinin şekilsel gösterimi.

Geliştirilen ESA ve YOLO modellerinin değerlendirilmesinde iki farklı doğruluk ölçütü kullanılmıştır. Plaka veya karakterin yerinin doğru olarak sınıflandırılmasında kullanılan doğruluk ölçütünün hesaplanması için formülü kullanılmaktadır (İşler 2009). Bu formülde verilen DP, DN, YP ve YN kısaltmaları bu çalışmada kullanılan ilk iki sınıflandırıcıda farklı anlamlara gelmektedir. Plaka yerinin tespiti olan birinci aşamada DP: plakayı içerecek şekilde doğru olarak işaretlenen görüntü parçası sayısını, DN: plaka içermeyen görüntü parçalarının doğru olarak işaretlendiği görüntü parçası sayısını, YP: plaka içermediği halde yanlışlıkla plaka varmış gibi işaretlenen görüntü parçası sayısını, YN: plaka içerdiği halde plaka yokmuş gibi işaretlenen görüntü parçası sayısını vermektedir. Plakadaki karakterlerin yerlerinin tespit edildiği ikinci aşamada DP: harf veya rakam içerecek şekilde doğru olarak işaretlenen görüntü parçası sayısını, DN: harf veya rakam içermeyen görüntü parçalarının doğru olarak işaretlendiği görüntü parçası sayısını, YP: harf veya rakam içermediği halde yanlışlıkla rakam veya harf varmış gibi işaretlenen görüntü parçası sayısını, YN: harf veya rakam içerdiği halde harf veya rakam yokmuş gibi işaretlenen görüntü parçası sayısını vermektedir.

Öte yandan, bu çalışmanın önceki aşamalarında yerleri zaten tespit edilmiş harf veya rakamların doğru olarak sınıflandırılmasında kullanılan doğruluk ölçütünün hesaplanması için formülü kullanılmaktadır (İşler 2009). Burada DP_i, i. harf veya rakamın doğru olarak sınıflandırılma sayısını ve N ise toplam harf ve rakam sayısını göstermektedir.

3. Sonuçlar ve Tartışma

Bu çalışmada araç plakalarının yerinin bulunması, plakalar üzerindeki karakterlerin belirlenmesi ve karakterlerin tanımlanması olmak üzere her aşaması için ayrı modelden oluşan üç aşamalı bir araç plaka tespit ve tanıma sistemi geliştirilmiş ve test edilmiştir. Bu kapsamda çevrimiçi paylaşılan iki veri seti kullanılırken karakter yeri belirlenmesi ve tüm sistemin test edilmesi için yeni veri seti daha oluşturulmuş ve sistemin geliştirilmesinde kullanılmıştır. Bu amaçla iki ayrı YOLO modeli ve bir ESA modeli oluşturulmuştur. İlk YOLO modeli araç plakasının yerini bulmak için, ikinci YOLO modeli ise araç plakası üzerindeki karakterlerin yerini bulmak için kullanılmıştır. Son aşamada ise karakterlerin sınıflandırılması için bir ESA modeli oluşturulmuştur.

YOLO ve ESA modelleri Python programlama dilinde Tensorflow ve Keras kütüphaneleri kullanılarak oluşturulmuştur. Bu derin öğrenme modellerinin eğitiminde yüksek işlem kapasiteleri bilgisayarlar kullanılması gerektiğinden,

geliştirme için Google Colab ortamı kullanılmıştır. Google Colab kısmen ücretsiz bir geliştirme ortamı olup <https://colab.research.google.com/> internet adresinden erişilebilir.

Bu eğitilmiş modeller, test verileri üzerinde sırasıyla plakanın bulunması, karakterlerin bulunması ve karakterlerin sınıflandırılması olacak şekilde test edilmiş ve sonuçları alınmıştır. Araç üzerindeki plaka yerinin bulunmasında ve plaka üzerindeki karakterlerin bulunmasında %100 başarı oranı elde edilmiştir. Plaka yeri doğru tahmin edilmiş plaka üzerindeki karakterlerin sınıflandırılmasında görüntü iyileştirme işlemi kullanılmadan %85.0 ve görüntü iyileştirme işlemi yapıldıktan sonra %94.9 sınıflandırıcı doğruluğu elde edilmiştir. 125 araçlık test verileri kullanılarak plaka yerinin bulunması, karakterlerin ayrıştırılması ve karakterlerin sınıflandırılması şeklindeki üç aşama birlikte değerlendirildiğinde %94.9 başarı oranına ulaşılmıştır. Literatürdeki benzer çalışmalarda elde edilen sonuçlar ile bu çalışmanın ilk aşamasında elde edilen sonuçlar bir tabloda özetlenmiştir (Çizelge 1). Bu çalışmalarda kullanılan yöntemler, veri setleri ve elde edilen sınıflandırıcı doğruluk değerleri bu çizelgede karşılaştırılmıştır. Buna göre bu çalışma ile elde edilen sonuçların tatmin edici olduğu görülmektedir.

Literatürdeki benzer çalışmalarda elde edilen sonuçlar ile bu çalışmanın son aşamasında elde edilen sonuçlar bir tabloda özetlenmiştir (Çizelge 2). Diğer çalışmalarda plaka üzerindeki karakterlerin yerlerin tespit edilmesi ayrı olarak verilmediğinden ikinci aşamaya ait sınıflandırıcı değerleri ayrıca karşılaştırılmamış ve tabloya karakter sınıflandırıcı sonuçları aktarılabilmştir. Bu çalışmalarda hem karakter tespitinde hem de karakter sınıflandırmasında kullanılan yöntemler, veri setleri ve üçüncü aşama için elde edilen sınıflandırıcı doğruluk değerleri bu çizelgede karşılaştırılmıştır. Buna göre diğer çalışmaların ayrı bir test veri seti kullanıp kullanmadığı bilinmemekle birlikte, bu çalışmanın test verisi sınıflandırıcı doğruluk değeri çizelgeye aktarılmıştır. Bu nedenle elde edilen plaka tanıma sınıflandırıcı başarısının tatmin edici düzeyde olduğu görülmektedir.

Sonuç olarak, literatürdeki çalışmalarda farklı çevre ve boyutlardaki veri setleri kullanıldığı için objektif bir karşılaştırma olanağı mümkün değildir. Bununla birlikte, bu çalışmada önerilen üç aşamalı sistem ile elde edilen sonuçların diğer çalışmalar kadar iyi olduğu görülmektedir. Çalışmanın ilk iki aşamasında görüntü iyileştirme gerek kalmadan mükemmel başarı elde edilebilmiştir. Bununla birlikte görüntü iyileştirme yöntemi kullanılmadan ve kullanılarak elde edilen sonuçlara bakıldığında, sistemin son aşamasında görüntü iyileştirme yöntemlerinin sisteme eklenmesiyle daha başarılı

Çizelge 1. Araç plaka yerinin tespiti çalışmalarının karşılaştırılması. Çalışmalarda plaka yerinin tespiti için kullanılan yöntem(ler), kullanılan veri set(ler)i ve çalışma sonucunda ulaşılan sınıflandırıcı doğruluk değerleri yüzde (%) olarak verilmiştir.

Çalışma	Yöntem	Veri seti	Doğruluk (%)
(Guo ve Liu 2008)	Renk özellikleri Hough dönüşümü	332 araç	93.6
(Li vd. 2013)	Kenar bulma Geometrik yöntemler	1418 araç	97.6
(Rafique vd. 2018)	R-ESA DVM	Pascal Voc2007 2871 araç	94.5
(Li vd. 2018)	YOLO	-	93.5
(Zhuang vd. 2018)	DeepLab V2 Resnet 101	AOLP 1874 araç Media Lab 706 araç Chinese Lic. 5057 araç	99.2
Bu çalışma	YOLO	433 araç	100

Çizelge 2. Araç plakasının tespiti sonrası plaka üzerindeki karakterlerin sınıflandırılması çalışmalarının karşılaştırılması. Çalışmalarda karakterlerin yerinin tespiti için kullanılan yöntem(ler), karakterlerin sınıflandırılması için kullanılan yöntem(ler), kullanılan veri set(ler)i ve çalışma sonucunda ulaşılan sınıflandırıcı doğruluk değerleri yüzde (%) olarak verilmiştir.

Çalışma	Karakter tespiti	Karakter sınıflandırma	Veri seti	Doğruluk (%)
(Anagnostopoulos vd. 2006)	Bağlı bileşen analizi	Olasılıksal sinir ağı	1334 araç	89.1
(Zhou vd. 2012)	SIFT	Kelime eşleme	Caltech Cars 522 araç	93.2
(Yuan vd. 2016)	Kenar bulma Bölütleme Çizgi yoğunluğu	DVM	Caltech Cars 3828 araç	96.6
(Rafique vd. 2018)	Bağlı bileşen analizi Rastgele örnekleme	DVM	8000 araç	91.4
(Li vd. 2018)	ESA R-ESA	DVM	460000 araç	91.4
(Shashidhar vd. 2021)	YOLO	YSA	Hint RTO 1500 görüntü	91.5
(Bayram 2020)	Elle tespit	Resnet 101	430 araç	98.4
(Bingöl ve Kuşçu 2008)	Görüntü işleme	-	100 araç	97.0
(Telatar ve Caasircioglu 2007)	Görüntü işleme	YSA	100 araç	98.8
(Çelik ve Oral 2021)	Görüntü işleme	YSA	105 araç	89.0
Bu çalışma	YOLO	Resim iyileştirme ESA	451 araç 48321 karakter	94.9

sonuçlar elde edilebileceği görülmektedir. Bu durum derin öğrenme modellerinin görüntüden doğrudan öznetelik çıkarabildiği ayrıca başka bir işleme gerek kalmadığı (Chollet 2018, Sürücü 2021a, Sürücü 2021b) inancına ters düşmekle birlikte aynı kaniya ulaşan başka çalışmalar (Sürücü vd. 2021) da mevcuttur. Gelecek çalışmalarda iyi bilinen diğer görüntü işleme yöntemlerinin de eklenmesiyle daha başarılı bir sonuç elde edilmesi planlanmaktadır.

Yazar katkıları

Emre Yücel: Çalışma hakkında verileri toplamış ve analiz etmiştir, Yalçın İşler: Çalışmanın analizlerini yaparak makaleyi yazmıştır, Yakup Kutlu: çalışmayı planlamış ve tasarlamış olup diğer iki yazarın tez danışmanıdır.

4. Kaynaklar

- Anagnostopoulos, CNE., Anagnostopoulos, IE., Loumos, V., Kayafas, E. 2006.** A license plate-recognition algorithm for intelligent transportation system applications. *IEEE Trans. Intell. Transp. Syst.*, 7(3):377-392. Doi: 10.1109/TITS.2006.880641
- Arısoy, MÖ., Dikmen, Ü. 2014.** Manyetik belirti haritalarının histogram eşitleme yöntemi kullanılarak iyileştirilmesi. *Yerbilimleri*, 35(2):141-168. Doi: <https://doi.org/10.17824/huyuamd.23614>
- Bayram, F. 2020.** Derin öğrenme tabanlı otomatik plaka tanıma. *Politeknik Dergisi*, 23(4):955-960. Doi: 10.2339/politeknik.515830
- Bilgin, A. 2021.** YOLO (You Only Look Once) mimarisi nedir? <https://aylablgn.medium.com/yolo-you-only-look-once-mimarisi-nedir-754d0bc6a6ba>. Yayın tarihi 30 Nisan 2021. Son erişim tarihi 16 Mayıs 2024.
- Bingöl, O., Kuşcu, Ö. 2008.** Bilgisayar tabanlı araç plaka tanıma sistemi. *Bilişim Teknolojileri Dergisi*, 1(3): 1-5. Url: <https://dergipark.org.tr/tr/pub/gazibtd/issue/6614/87879>
- Chollet, F. 2018.** *Deep Learning with Python. 2. baskı*, Manning Yayınevi.
- Çağıl, G., Yıldırım, B. 2020.** Bir montaj parçasının derin öğrenme ve görüntü işleme ile tespiti. *Zeki Sistemler Teori ve Uygulamaları Dergisi*, 3(2):31-37. Doi: 10.38016/jista.710144
- Çay, T., Ölmez, E., Er, O. 2023.** Bölgesel tabanlı evrişimli sinir ağı ile araç plaka tanıma. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(1):10-20. Doi: 10.29130/dubited.1058850
- Çelik, U., Oral, M., 2003.** Motorlu araçlar için plaka tanıma sistemi. *Elektrik Elektronik- Bilgisayar Mühendisliği 10. Ulusal Kongre ve Fuarı, İstanbul*, 17-21 Eylül, s. 499-502.
- Du, S., Ibrahim, M., Shehata, M., Badawy, W. 2017.** Automatic license plate recognition (ALPR): A state-of-the-art review. *IEEE Trans. Circuits Syst. Video Technol.*, 23(2):311-325. Doi: 10.1109/TCSVT.2012.2203741
- Gonzalez, RC., Woods, RE. 2007.** *Digital Image Processing. 3. baskı*, ISBN: 978-0131687288, Prentice Hall International.
- Guo, JM., Liu, YF. 2008.** License plate localization and character segmentation with feedback self-learning and hybrid binarization techniques. *IEEE Trans. Veh. Technol.*, 57(3):1417-1424. Doi: 10.1109/TVT.2007.909284
- İşler, Y. 2009.** A detailed analysis of the effects of various combinations of heart rate variability indices in congestive heart failure. *Doktora tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, İzmir*, s. 166.
- Jelal. 2021.** License plate digits classification dataset. <https://www.kaggle.com/aladdinss/license-plate-digits-classification-dataset> Yayın tarihi 5 Haziran 2021. Erişim tarihi 29 Aralık 2023.
- Laroca, R., Severo, E., Zanlorensi, LA., Oliveira, LS., Gonçalves, GR., Schwartz, WR., Menotti, D. 2018.** A robust real-time automatic license plate recognition based on the YOLO detector. *International Joint Conference on Neural Networks (IJCNN)*, Rio de Janeiro, Brazil, 1-10. Doi: 10.1109/IJCNN.2018.8489629.
- Larxel. 2020.** Car license plate detection dataset. <https://www.kaggle.com/andrewmvd/car-plate-detection>. Yayın tarihi 1 Haziran 2020. Son erişim tarihi 29 Aralık 2023.
- Li, B., Tian, B., Li, Y., Wen, D. 2013.** Component-based license plate detection using conditional random field model. *IEEE Trans. Intell. Transp. Syst.*, 14(4):1690-1699. Doi: 10.1109/TITS.2013.2267054
- Li, H., Wang, P., Shen, C. 2018.** Toward end-to-end car license plate detection and recognition with deep neural networks. *IEEE Trans. Intell. Transp. Syst.*, 20(3):1126-1136. Doi: 10.1109/TITS.2018.2847291
- Narin, A., İşler, Y. 2021.** Detection of new coronavirus disease from chest x-ray images using pre-trained convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(4):2095-2107. Doi: 10.17341/gazimmfd.827921
- Özbay, S., Erçelebi, E. 2005.** Automatic vehicle identification by plate recognition. *World Acad. Eng. Technol.*, 9(41):222-225. Doi: 10.5281/zenodo.1331865
- Panahi, R., Gholampour, I. 2016.** Accurate detection and recognition of dirty vehicle plate numbers for high-speed applications. *IEEE Trans. Intell. Transp. Syst.*, 18(4):767-779. Doi: 10.1109/TITS.2016.2586520
- Rafique, MA., Pedrycz, W., Jeon, M. 2018.** Vehicle license plate detection using region-based convolutional neural networks. *Soft Comput.*, 22(19):6429-6440. Doi: 10.1007/s00500-017-2696-2
- Redmon, J., Divvala, S., Girshick, R., Farhadi, A. 2016.** You only look once: Unified, real-time object detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 779-788. Doi: 10.1109/CVPR.2016.91
- Shashidhar, R., Manjunath, AS., Kumar, RS., Roopa, M., Puneeth, SB. 2021.** Vehicle number plate detection and recognition using YOLO-V3 and OCR method. *2021 IEEE International Conference on Mobile Networks and Wireless Communications (ICMNWC)*, 1-5, Tumkur, Karnataka, India. Doi: 10.1109/ICMNWC52512.2021.9688407

- Shinde, S., Kothari, A., Gupta, V. 2018.** YOLO based human action recognition and localization. *Procedia Comput. Sci.*, 133:831-838. Doi: 10.1016/j.procs.2018.07.112
- Sürücü, M., İşler, Y., Perc, M., Kara, R. 2021.** Convolutional neural networks predict the onset of paroxysmal atrial fibrillation: Theory and applications. *Chaos*, 31(11):34881615. Doi: 10.1063/5.0069272
- Sürücü, M. 2022a.** Predicting capacity change in li-ion batteries using regression models. *J. Intell. Syst. Appl.*, 5(2):120-125. Doi: 10.54856/jiswa.202212229
- Sürücü, M. 2022b.** Improvement of CNN network parameters in turkish music emotion recognition. *J. Intell. Syst. Appl.*, 5(2):126-131. Doi: 10.54856/jiswa.202212230
- Telatar, Z., Çamaşırçoğlu, E. 2007.** Plate detection and recognition by using colour information and ANN. 2007 IEEE 15th Signal Processing and Communications Applications, Eskisehir, Turkey, 1-4. Doi: 10.1109/SIU.2007.4298583.
- TÜİK. 2024.** Motorlu Kara Taşıtları (Nisan 2024). 53456 nolu yayın. <https://data.tuik.gov.tr/Bulten/Index?p=Motorlu-Kara-Tasitlari-Nisan-2024-53456> Yayın tarihi 1 Mayıs 2024. Son erişim tarihi 27 Temmuz 2024.
- Yuan, Y., Zou, W., Zhao, Y., Wang, X., Hu, X., Komodakis, N. 2016.** A robust and efficient approach to license plate detection. *IEEE Trans. Image Process.*, 26(3):1102-1114. Doi: 10.1109/TIP.2016.2631901
- Zhou, W., Li, H., Lu, Y., Tian, Q. 2012.** Principal visual word discovery for automatic license plate detection. *IEEE Trans. Image Process.*, 21(9):4269-4279. Doi: 10.1109/TIP.2012.2199506
- Zhuang, J., Hou, S., Wang, Z., Zha, ZJ. 2018.** Towards human-level license plate recognition. *Proceedings of the European Conference on Computer Vision (ECCV)*, 306-321. Doi: 10.1007/978-3-030-01219-9_19