



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Derin öğrenme tabanlı otomatik plaka tanıma

Automatic license plate recognition based on deep learning

Yazar(lar) (Author(s)): Fatih BAYRAM

ORCID: 0000-0001-9578-9478

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Bayram F., “Derin öğrenme tabanlı otomatik plaka tanıma”, *Politeknik Dergisi*, 23(4): 955-960, (2020).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.515830


Derin Öğrenme Tabanlı Otomatik Plaka Tanıma

Automatic License Plate Recognition Based on Deep Learning

Önemli noktalar (Highlights)

- ❖ Maskeli Bölgesel Evrişimsel Sinir Ağı (Mask Region Based Convolutional Neural Network)

Grafik Özet (Graphical Abstract)



Şekil. M-BESA Mimarisi /Figure. Mask-RCNN architecture

Amaç (Aim)

Bu çalışmada kamera görüntüsü üzerinden plaka karakterlerini otomatik olarak tanıyabilen bir sistem geliştirilmesi amaçlanmıştır. / In this study, it is aimed to develop a system that can automatically recognize license plate characters from the camera image.

Tasarım ve Yöntem (Design & Methodology)

Geliştirilen sistem görüntüden bölgesel nesne tanımda oldukça başarılı olan M-BESA yöntemini kullanmaktadır. Bu yöntemde bölge hizalama katmanından sonra, tekrar evrişim katmanları uygulanarak nesnelerin ikili maskesi elde edilmektedir. / The developed system uses the Mask-RCNN method, which is very successful in regional objects recognition on image. In this method, after the region alignment layer, the convolution layers are reapplied to obtain the binary masks of objects.

Özgünlük (Originality)

Diğer geleneksel yöntemlerden farklı olarak önerilen model; plaka konumunu tespit etmek, plakadaki karakterlerin konumunu tespit etmek gibi ek aşamalara gerek duymadan doğrudan karakter tanıma işlemi gerçekleştirebilmektedir. / Unlike other traditional methods, the proposed model; It can perform character recognition without the need for additional steps such as determining the position of the plate, determining the position of the plate characters.

Bulgular (Findings)

Sonuçlar, önerilen sistemin diğer çalışmalara kıyasla daha başarılı olduğunu göstermektedir. / The results show that the proposed system is more successful than other studies.

Sonuç (Conclusion)

M-BESA modeli ve karakter maskelerinin kullanılması otomatik plaka tanıma uygulamalarında performansı arttırmaktadır. / Using Mask-RCNN model and character masks increases performance in automatic license plate recognition applications.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazarı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Derin Öğrenme Tabanlı Otomatik Plaka Tanıma

Araştırma Makalesi / Research Article

Fatih BAYRAM*

Teknoloji Fakültesi, Mekatronik Mühendisliği, Afyon Kocatepe Üniversitesi, Türkiye

(Geliş/Received : 21.01.2019 ; Kabul/Accepted : 18.09.2019)

ÖZ

Günümüzde araç sayısındaki artış plaka tanıma sistemlerine olan ihtiyacı arttırmıştır. Otomatik plaka tanıma sistemleri trafik denetim işlemleri, otoyol geçişleri, otopark giriş-çıkış kontrolleri ve daha birçok alanda yaygın olarak kullanılmaktadır. Geleneksel görüntü işleme teknikleri ile ham görüntü çok fazla ön işlemden geçirilmesi gerekmekte iken, bu alandaki son gelişmelerle birlikte ön işleme süreçleri önemli ölçüde azalmış ve başarı oranları artmıştır.

Bu çalışmada kamera görüntülerinden otomatik olarak plaka tanıyabilen bir sistem geliştirilmiştir. Geliştirilen sistem bilgisayarla görü alanındaki en ileri derin öğrenme tekniklerinden olan Maskeli Bölgesel Evrimsel Sinir Ağları (M-BESA) tabanlıdır. Bu makalede evrimsel sinir ağları ve kullanılan M-BESA modeli elde edilen sonuçlarıyla birlikte açıklanmıştır.

Anahtar Kelimeler: Otomatik plaka tanıma, derin öğrenme, maskeli bölgesel evrimsel sinir ağları.

Automatic License Plate Recognition Based on Deep Learning

ABSTRACT

Nowadays, the increase in the number of vehicles has enhanced the importance of automatic license plate recognition systems. The automatic license plate recognition systems has widely used in areas of traffic control operations, highway crossings, car park entrance-exit controls etc. As the traditional image processing techniques have a need of raw image's excessive pre-processing, with the recent advances in this area have significantly decreased the pre-processing processes and increased the performance rates. This study presents a system that automatically recognizes the images of the license plates observed from camera. The developed system is based on Mask Region Based Convolutional Neural Networks (Mask-RCNN) which is the state-of-the-art deep learning techniques in the field of computer vision. In this study, convolutional neural networks, Mask-RCNN and the obtained results of Mask-RCNN have been explained.

Keywords: Automatic license plate recognition, deep learning, mask region based convolutional neural networks.

1. GİRİŞ (INTRODUCTION)

Geleneksel plaka tanıma sistemleri araç plakası konum tespiti ve plakada bulunan karakterlerin tespiti olarak iki aşamadan meydana gelir. Şimdiye kadar kullanılmakta olan plaka tanıma sistemleri kenar bulma tabanlı, renk tabanlı, doku tabanlı veya karakter tabanlı gibi geleneksel görüntü işleme yöntemleri kullanılarak geliştirilmekteydi. Fakat günümüzde ortaya çıkan bilgisayarla görü alanındaki gelişmeler herhangi bir ön işleme gerektirmeden doğrudan ham görüntü üzerinden plaka tanımaya imkân vermektedir.


2. EVRİŞİMSEL SİNİR AĞLARI

(CONVOLUTIONAL NEURAL NETWORKS)

Evrimsel sinir ağları, 2012 yılında büyük ölçekli görsel tanıma (ILSVRC) adlı yarışmada elde ettiği başarı ile adından söz ettirmiş ve tam anlamıyla görüntü işleme ve bilgisayarla görü alanlarında yeni bir çığır açmıştır [1]. Google, Microsoft, Samsung, Qualcomm vb. birçok teknoloji şirketinin takımlar halinde katılım sağladığı bu

yarışma 2010 yılında başlamış ve her sene düzenlenmeye devam etmektedir.

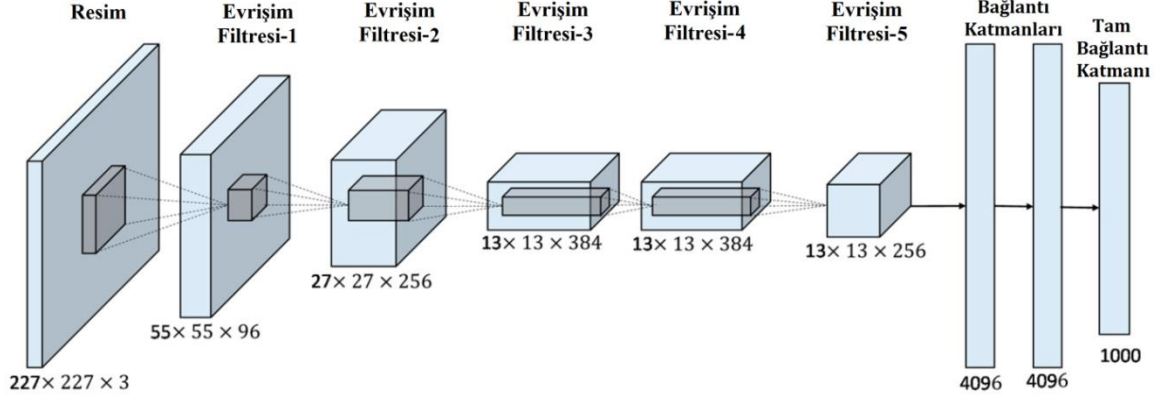
Yarışma yüksek çözünürlüğe sahip yaklaşık 1,2 milyon görüntüden oluşan veriseti ile gerçekleştirilmektedir. Yarışmada 2010-2015 yılları arasında katılımcıların geliştirdikleri evrimsel sinir ağı modelleri sayesinde görüntü sınıflandırma hata oranı 7,89 kat (%28,2'den %3,57'ye) ve nesne tespiti hata oranı 4,7 kat (%42,5' ten %9'e) azalmıştır. Şekil 1'de 2010-2015 yılları arasında gerçekleştirilen yarışmaları kazanan takımların görüntü sınıflandırma hata oranları verilmiştir [2].



Şekil 1. 2010-2015 yılları arasında ILSVRC'de elde edilen görüntü sınıflandırma hata oranları ve katman sayıları [3]. (The error rates and layer numbers of image classification obtained from ILSVRC 2010 to 2015)

*Sorumlu Yazar (Corresponding Author)
e-posta : fatihbayram@aku.edu.tr

Şekil 1’de görüleceği üzere AlexNet ile 2012 yılında evrişimsel sinir ağları ile elde edilen başarı her sene geliştirilmiştir. Bu geliştirmelerde sinir ağındaki katman sayılarının artırılması ve böylece ağı daha derin bir yapıya kavuşması büyük pay sahibidir. Şekil 2’de AlexNet evrişimsel sinir ağı ve katmanları görülmektedir.



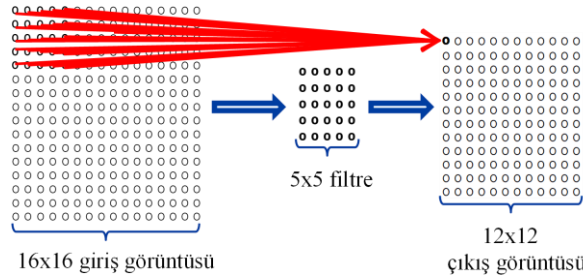
Şekil 2. AlexNet evrişimsel sinir ağı ve katmanları [7] (AlexNet convolutional neural network and its layers)

Derin öğrenme temelli bu sinir ağları sayesinde artık çok sayıda görüntü işleme süreçleri ve sınıflandırıcı işlemlerinin yerine tek bir ağ yapısı ile görüntü sınıflama, nesne tanıma ve nesne konumu tespitinde yüksek başarı oranları yakalanabilmektedir.

Evrişimsel sinir ağlarında nesne özellikleri klasik görüntü işlemeden farklı olarak programcı tarafından elde edilmez, oluşturulan model kendi kendine öğrenerek en uygun özellikleri seçer. Bunun için de yapay sinir ağlarından farklı olarak evrişim katmanı ve havuzlama katmanı kullanılmaktadır. Daha sonradan evrişim sinir ağlarının geliştirilmesi ile birlikte ağı doğrusal olmayan bir yapıya kavuşturmak için aktivasyon katmanı ve ağın ezberlemesine engel olmak için daha az ağırlıklara sahip düğümlerin kaldırılmasını sağlayan dışarıda bırakma katmanı eklenmiştir. Ağı son katmanı da sinir ağı sınıflandırma tahmini yapması için önceki katmanlardan gelen tüm özellikleri birleştirerek tek boyutlu bir özellik vektörü haline getiren tam bağlantı katmanıdır [4,5,6].

2.1. Evrişim Katmanı (Convolution Layer)

Ana katman olan evrişim katmanı görüntü üzerinde 2x2,3x3,5x5 vb. değişik boyutlarda filtrenin uygulanması işlemidir. Filtre tüm görüntü üzerinde kaydırma yapılarak gezdirilir.



Şekil 3. 16x16 boyutundaki bir görüntüye 5x5 filtre uygulanması (Applying a 5x5 filter to a 16x16 size image)

Kaydırma adım sayısı ve filtre boyutu programlayıcı tarafından belirlenir. Filtre her satır sonuna geldiğinde bir alt satıra iner, bu işlem görüntünün sonuna kadar devam etmektedir [8,9]. Şekil 3’de 16x16 boyutundaki bir görüntüye 5x5 boyutunda bir filtre ile evrişim işlemi uygulanması işlemi görülmektedir.

Evrişim işlemi sırasında filtre çerçevesi içerisinde kalan piksel değerleri filtrenin değerleri ile çarpılır ve elde edilen değerler toplanarak çıkış görüntüsünün bir pikselinin değeri olarak kaydedilir. Şekil 4’te evrişim operatörünün uygulanması işlemi görülmektedir.

$$\begin{bmatrix} 3 & 5 & 2 \\ 9 & 7 & 5 \\ 2 & 4 & 6 \end{bmatrix} \times \begin{bmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \Rightarrow \begin{bmatrix} (3 \times 1) + (5 \times 0) + (2 \times 0) + \\ (9 \times 1) + (7 \times 1) + (5 \times 0) + \\ (2 \times 0) + (4 \times 0) + (6 \times 1) \end{bmatrix} = 25$$

Şekil 4. Evrişim operatörünün uygulanması (Application of convolution operator)

Giriş görüntüsü üzerinde birden fazla evrişim işlemi uygulanarak ağı derinliği artırılmış ve ağı daha doğru sonuçlar vermesi sağlanmış olur. Her evrişim katmanında filtre kendinden önceki evrişim katmanlarında elde edilen görüntülere uygulanır. Böylece giriş görüntüsünün en boy oranı düşürülürken derinliği artırılmış ve en sonunda görüntünün özellik haritası ortaya çıkarılmış olur. Alt seviye katmanlardan elde edilen özellikler daha az ayırt ediciliğe sahipken alt katmanların birleştirilmesinden oluşan üst seviye katmanlar ise daha çok ayırt ediciliğe sahiptir. (Şekil 5)


Alt Katmanlar → Üst Katmanlar

Şekil 5. Evrişim işlemi ile katmanlar da elde edilen özelliklerin ayırt edicilikleri (The distinctive features of convolution process on layers)

2.2 Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanında bir önceki katman evrişim katmanında olduğu gibi gelen görüntü üzerinde değişik boyutlarda filtreler gezdirilir. Bu katmandaki filtrelerin evrişim katmanında uygulanan filtrelerden farkı ise

maksimum veya ortalama alan filtreler olmasıdır [10,11]. Şekil 6'da havuzlama katmanındaki filtrelerin uygulanma işlemi gösterilmiştir.



Şekil 6. 4x4 boyutunda görüntüye 2x2 boyutunda maksimum ve ortalama havuzlama operatörünün uygulanması (The implementation of 2x2 maximum and average pooling filter to 4x4 image)

Maksimum havuzlamada filtre penceresi içerisinde kalan piksel değerlerinden en yüksek olanı, ortalama havuzlama işleminde ise filtre penceresi içerisinde kalan tüm piksel değerlerinin ortalaması alınarak çıkış pikseline tek bir değer olarak kaydedilir. Havuzlama işlemi sonunda görüntünün en boy oranı indirgenmiş olur. Bu işlemde piksel değerlerinde kayıplar olur fakat bu kayıplar sonraki katmanlar için daha az hesaplama yükü oluşturacağı ve sistemin ezberlemesini önlediği için getirisi daha fazladır.

3. BÖLGESEL EVRİŞİMSSEL SİNİR AĞLARI (REGION BASED CONVOLUTIONAL NEURAL NETWORKS)

Nesne sınıflandırma işleminde girilen görüntünün sınıfı ve o sınıfa ait olma yüzdesi çıkış olarak elde edilir. Fakat nesne tespiti işlemi, nesnenin veya nesnelerin sınıfı ve o sınıfa ait olma yüzdesi ile birlikte görüntü içerisindeki konumunu kutu şeklinde ifade eden x koordinatı, y koordinatı, genişlik ve yükseklik değerleri çıkış olarak elde edildiği karmaşık bir işlemdir. Örnek bölütleme ise görüntüdeki her pikselin ait olduğu sınıfı yani nesneye ait tüm koordinatların çıkış olarak elde edildiği daha da karmaşık bir işlemdir.

Evrışimsel sinir ağları, nesne sınıflandırmada olduğu gibi bu karmaşık işlemlerde de başarılı sonuçlar elde etmiştir. İlk defa 2014 yılında Girshick ve arkadaşlarının [12] ortaya koymuş olduğu bölgesel evrışimsel sinir ağları ile nesne tespitinde önceki yöntemlere göre önemli ölçüde yüksek performanslar elde etmişlerdir. İlk ortaya konan bölgesel evrışimsel sinir ağından sonra çeşitli hız ve performans geliştirmeleri yapılmıştır [13,14]. Son olarak 2017 yılında yapılan geliştirme ile nesne bölütleme yeteneği kazanmış ve maskeli bölgesel evrışimsel sinir ağları olarak adlandırılmıştır [15]. Şekil 7'de maskeli bölgesel evrışimsel sinir ağı yapısı gösterilmiştir.

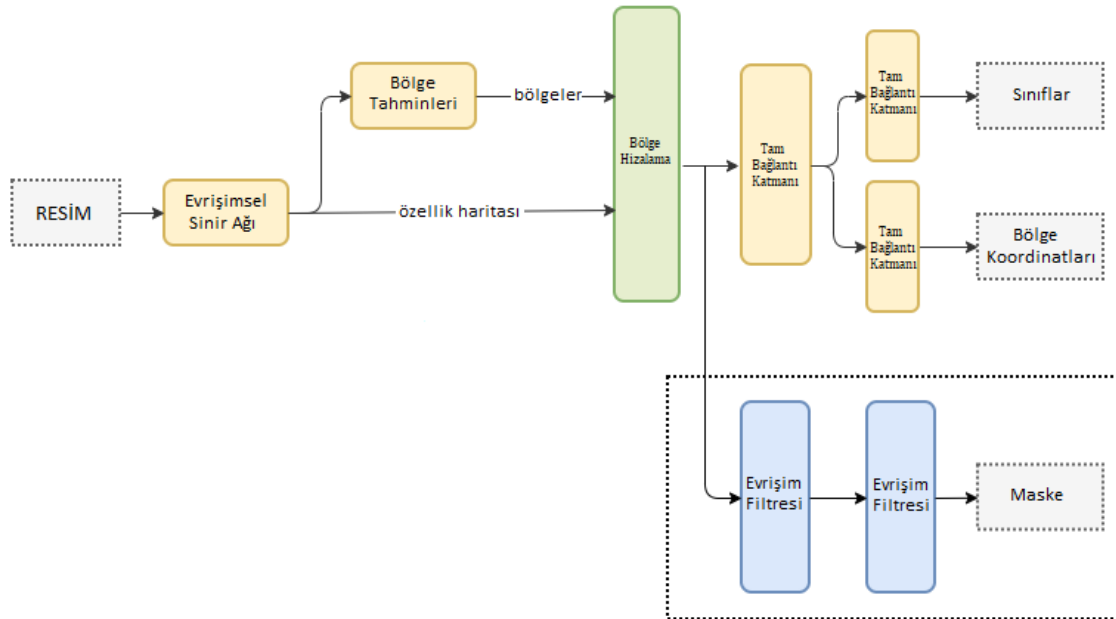
4. MATERİYAL VE METOT (MATERIAL AND METHOD)

Önerilen otomatik plaka tanıma sistemi, üç ana adımdan oluşmaktadır. Adımlar; araç görüntülerindeki plaka karakterlerinin manuel olarak etiketlenmesi, maskeli bölgesel evrışimsel sinir ağı tasarımını ve eğitilmesi ile plaka tanıma detektörünün elde edilmesi ve değerlendirilmesidir.

Çizelge 1. Görüntü veriseti dağılımı (The distribution of image dataset)

	Eğitim	Test	Toplam
Plaka Görüntüsü	300	130	430
Karakter Görüntüsü	2165	975	3140

Bu çalışmada 1920x1075 boyutlarında ve 430 adet araç görüntüsünden oluşan bir veriseti kullanılmıştır. Veri setinde bulunan görüntüler üzerinde herhangi bir görüntü iyileştirme veya düzeltme işlemi yapılmadan doğrudan sinir ağına verilmiştir. 430 adet araç plakasından elde



Şekil 7. Maskeli bölgesel evrışimsel sinir ağı yapısı [16] (The structure of Mask-RCNN)

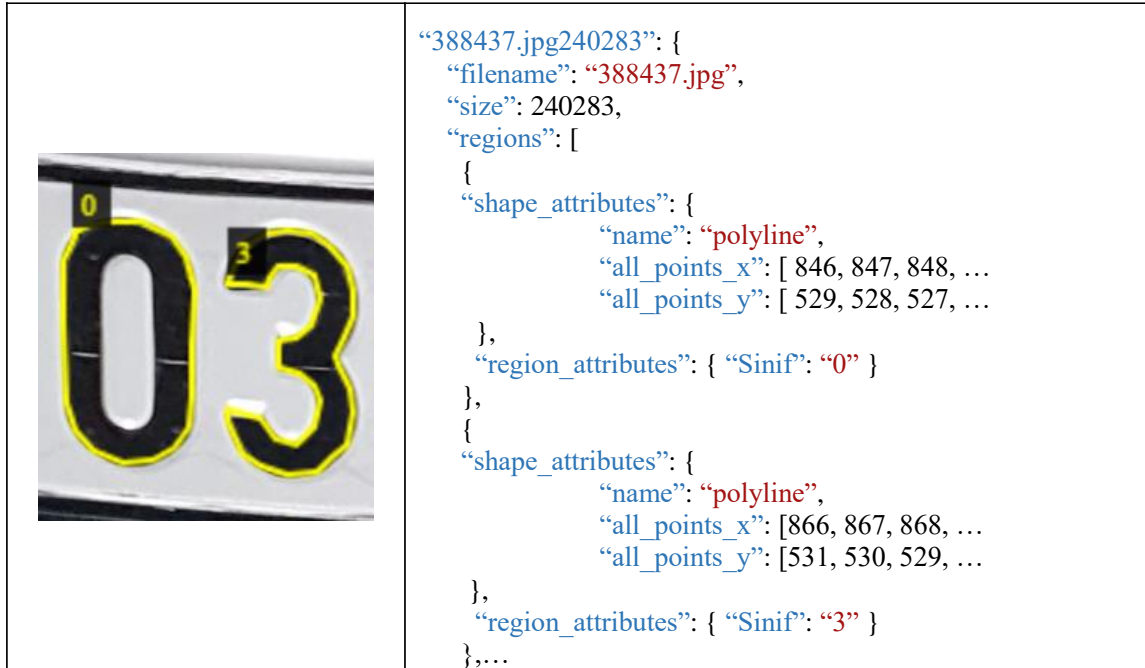
edilen toplam 3140 karakter ile oluşturulan görüntü verisetinin dağılımı Çizelge 1’de verilmiştir.

Türk plaka sisteminde 1 ve 0 gibi rakamlar ile karışıklığa yol açabileceği için I ve O gibi harfler plaka karakteri olarak nadiren kullanılmaktadır, yine plakalarda Ç, Ğ, İ, Ö, Ş, Ü gibi türkçe karakterler kullanılmadığı için verisetinden bu 8 karakter çıkartılmıştır. Çizelge 2’de plaka görüntülerindeki karakterlerin dağılımları verilmiştir.

Çizelge 2. Plakalardan elde edilen karakterlerin dağılımı (The distribution of characters obtained from license plates)

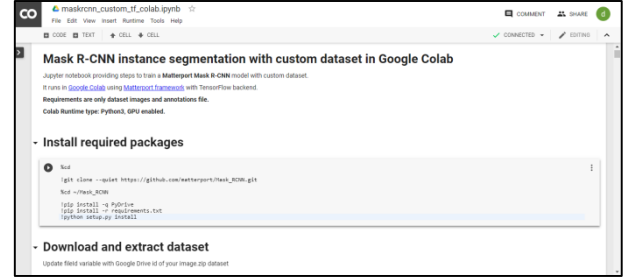
KARAKTER	#	KARAKTER	#	KARAKTER	#	KARAKTER	#	KARAKTER	#
A	95	H	38	R	41	0	452	5	170
B	107	J	20	S	28	1	141	6	198
C	35	K	32	T	34	2	173	7	147
D	61	L	41	U	45	3	454	8	157
E	49	M	29	V	53	4	216	9	119
F	43	N	44	Y	35				
G	27	P	33	Z	23				
TOPLAM KARAKTER:									3140

Maskeli bölgesel evrişimsel sinir ağları piksel bazında bölütleme yaptığı için diğer bölgesel evrişimsel sinir ağlarından farklı olarak nesne konumlarının sadece dikdörtgen olarak koordinatlarına değil, tespit edilecek nesnelere ait bütün koordinatlara ve o koordinatların ait olduğu sınıflara ihtiyaç duyar. Bu yüzden araç görüntülerdeki etiketleme işleminde plakalarda yer alan tüm karakterler dikdörtgen şeklinde değil çokgenler şeklinde sınıflarına göre tek tek etiketlenmiştir. Etiketleme işlemi Oxford üniversitesi tarafından geliştirilen VIA görüntü etiketleme uygulamasında gerçekleştirilmiştir [17]. Görüntü etiketleme işlemi ile elde edilen koordinatlar json formatında kaydedilmiş ve ağın eğitiminde kullanılmıştır. Şekil 8’de VIA görüntü etiketleme uygulamasıyla etiketlenmiş plaka karakter örneği ve json formatındaki çıktısı gözükmektedir.



Şekil 8. Etiketlenmiş plaka karakterleri ve json formatında çıktısı (The labeled license plate characters and the output in json format)

Maskeli bölgesel evrişim sinir ağının eğitimi ve test edilmesi işlemleri için Google Colaboratory veya kısa adıyla Colab bulut sistemi kullanılmıştır [18]. Bu sistemin avantajı NVIDIA Tesla K80 grafik işlemcisi ile büyük veriler üzerinde çok fazla hesaplama işlemini hızlı bir şekilde yapabileceğiniz bulut teknolojisini ücretsiz olarak hizmete sunmasıdır. Şekil 9’da Google Colaboratory çalışma ortamına ait bir ekran görüntüsü verilmiştir.



Şekil 9. Google Colaboratory çalışma ortamı (Google Colaboratory working environment)

Colab’ta uygulanabilirliği ve performansı yüksek olması nedeniyle Python 3, Keras ve TensorFlow kullanılarak geliştirilen açık kaynak kodlu bir maskeli bölgesel evrişimsel sinir ağı modeli kullanılmıştır [19]. Bu modelde standart evrişimsel sinir ağı olarak önceden eğitilmiş Resnet-101 kullanılmış ve sinir ağının başlangıç ağırlıkları olarak coco veriseti ağırlıkları belirlenmiştir [20,21]. Eğitim sonunda elde edilen otomatik plaka tanıma dedektörüne giriş olarak verilen araç görüntülerinden elde sonuçlar Şekil 10’da gösterilmiştir.



Şekil 10. Otomatik plaka tanıma dedektörü ile elde edilen sonuçlar (The results obtained from automatic license plate recognition detector)

Otomatik plaka tanıma dedektörü ile plaka bazında elde edilen test sonuçları Çizelge 3'te verilmiştir.

Çizelge 3. Plaka tanıma test sonuçları (The test results of license plate recognition)

	Sayısı	Hatalı Tespit	Başarım Oranı
Toplam Plaka	130	2	% 98,46

Otomatik plaka tanıma ve plaka tespiti konusunda geleneksel ve modern yöntemlerle yapılmış olan çalışmaların karşılaştırma tablosu Çizelge 4'te verilmiştir.

5. SONUÇLAR (CONCLUSION)

Bu çalışmada araç görüntüleri üzerinden plaka karakterlerinin sınıfını ayırt edebilen plaka tanıma sistemi önerilmiştir.

Çizelge 4. Otomatik plaka tanıma ve plaka tespiti konusunda yapılmış olan çalışmaların karşılaştırma tablosu (Comparison table of performed previously in literature about automatic plate recognition and plate detection)

Metot	Uygulama	Kullanılan Yöntemler	Başarım Oranı (%)	Süre (ms)
Anagnostopoulos ve ark. [22]	Plaka Tanıma	Kayan Ortak Merkezli Pencere, Bağlı bileşenler analizi, Olasılıksal Sinir Ağları	89.10	276
Zhou ve ark. [23]	Plaka Tespiti	Görsel Kelime Eşleme, SIFT	93.20	220
Guo ve ark. [25]	Plaka Tanıma	Renk özellikleri, Hough Dönüşümü	93.60	594
Yuan ve ark. [26]	Plaka Tespiti	Kenar Bulma, Bölütleme, Çizgi Yoğunluk Filtreleme, SVM sınıflandırıcı	96.62	42
Li ve ark. [24]	Plaka Tespiti	Kenar Bulma, Geometrik-Görsel Öznitelik Çıkarma	97.60	767
Panahi ve ark. [27]	Plaka Tanıma	Bağlı bileşenler analizi, Rasgele Örnekleme, Olasılıksal SVM	97.60	180
Derin Öğrenme Tabanlı Yöntemler				
Laroca ve ark. [28]	Plaka Tanıma	YOLO	93.53	21
Rafique ve ark. [29]	Plaka Tespiti	RCNN, SVM	94.53	350
Li ve ark. [30]	Plaka Tanıma	CNN, RCNN	96.57	400
Geliştirilen Sistem	Plaka Tanıma	Mask-RCNN	98.46	400
Bulan ve ark. [31]	Plaka Tanıma	Gizli Markov modelleri, CNN	99.00	2000
Zhuang ve ark. [32]	Plaka Tanıma	DeeplabV2 ResNet-101	99.25	-

Önerilen sistemde, plaka karakterlerinin başarılı bir şekilde sınıflandırabilmesi için derin öğrenme tabanlı maskeli bölgesel evrişimsel sinir ağı kullanılmıştır. Evrişimsel sinir ağları eğitim esnasında her bir karaktere özgü özellikleri öğrenebilmekte böylece klasik sınıflandırıcılardan daha efektif başarımlarına ulaşabilmektedir. Ayrıca maskeli bölgesel evrişimsel sinir ağlarında giriş olarak nesnelerin tüm dış kenar koordinatlarının verilmesi de nesne konumunun tespit edilmesi işlemini ortadan kaldırarak daha hızlı bir model performansı ortaya koymaktadır. Gerçekleştirilen test sonuçlarına göre toplam 130 adet 1920x1075 boyutlarındaki araç görüntüsü üzerindeki plaka tanıma başarımları %98.46 ve plaka tanıma işlemi ortalama 0,4 sn. gibi kısa bir sürede gerçekleştirilebilmektedir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

KAYNAKLAR (REFERENCES)

- [1] Krizhevsky A., Sutskever I. and Hinton G. E., "Imagenet classification with deep convolutional neural networks", *Advances in Neural Information Processing Systems*, 25:1097-1105, (2012).
- [2] *ImageNet Large Scale Visual Recognition Competition (ILSVRC)*, <http://image-net.org/challenges/LSVRC>
- [3] He K., "Deep Residual Learning for Image Recognition", http://cvlab.postech.ac.kr/~bhhan/class/cs_e703r_2016s/Hyeongseok_Deep_Residual_Learning_for_Image_Recognition.pptx, (2016).
- [4] Arı A., and Hanbay D., "Bölgesel Evrişimsel Sinir Ağları Tabanlı MR Görüntülerinde Tümör Tespiti", *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 18(2), (2018).
- [5] Kızrak A. and Bolat B., "Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma", *Bilişim Teknolojileri Dergisi*, 11:263-286, (2018).
- [6] Uçar A. and Bingöl M. S., "Derin öğrenmenin Caffe kullanılarak grafik işleme kartlarında değerlendirilmesi", *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 39-49, (2018)
- [7] Han X., Zhong Y., Cao L. and Zhang L., "Pre-Trained AlexNet Architecture with Pyramid Pooling and Supervision for High Spatial Resolution Remote Sensing Image Scene Classification", *Remote Sensing*, 9:848, (2017).
- [8] İnik Ö. and Ülker E., "Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri", *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3):85-104, (2017).
- [9] Doğan F., and Türkoğlu İ., "Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması", *Sakarya University Journal of Computer and Information Sciences*, 1(1):10-21, (2018).
- [10] Civaner O. F. and Kamaşak M., "Classification of pediatric snoring episodes using deep convolutional neural networks", *Signal Processing and Communications Applications Conference*, İzmir, 1-4, (2018).
- [11] Cengil, E. and Çınar A., "A New Approach for Image Classification: Convolutional Neural Network", *European Journal of Technic*, 6(2):96-103, (2016).
- [12] Girshick R., Donahue J., Darrell T. and Malik J., "Rich feature hierarchies for accurate object detection and semantic segmentation", *Computer Vision and Pattern Recognition*, 580-587, (2014).
- [13] Girshick R., "Fast R-CNN", *Proceedings of the IEEE International Conference on Computer Vision*, Washington-USA, 1440-1448, (2015).
- [14] Ren S., He K., Girshick R. and Sun J., "Faster R-CNN: Towards real-time object detection with region proposal networks", *Advances in Neural Information Processing Systems*, 28: 91-99, (2015).
- [15] He K., Gkioxari G., Dollár P. and Girshick, R., "Mask R-CNN", *International Conference on Computer Vision*, Venice-ITALY, 2980-2988, (2017).
- [16] https://medium.com/@jonathan_hui/image-segmentation-with-mask-r-cnn-eb6d793272
- [17] Dutta, A., Gupta A. and Zissermann A., VGG Image Annotator, <http://www.robots.ox.ac.uk/~vgg/software/via>
- [18] Google Colaboratory, <https://colab.research.google.com>.
- [19] Waleed A., Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow, https://github.com/matterport/Mask_RCNN
- [20] Common Objects in Context, <http://cocodataset.org>
- [21] He K., Zhang X., Ren S. and Sun J., "Deep Residual Learning for Image Recognition", *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas-USA, 770-778, (2016).
- [22] Anagnostopoulos, C. N. E., Anagnostopoulos, I. E., Loumos, V. and Kayafas, E., "A license plate-recognition algorithm for intelligent transportation system applications", *IEEE Transactions on Intelligent Transportation Systems*, 7(3):377-392, (2006).
- [23] Zhou, W., Li, H., Lu, Y. and Tian, Q., "Principal visual word discovery for automatic license plate detection", *IEEE Transactions on Image Processing*, 21(9):4269-4279, (2012).
- [24] Li, B., Tian, B., Li, Y. and Wen, D., "Component-based license plate detection using conditional random field model", *IEEE Transactions on Intelligent Transportation Systems*, 14(4):1690-1699, (2013).
- [25] Guo, J. M. and Liu, Y. F., "License plate localization and character segmentation with feedback self-learning and hybrid binarization techniques", *IEEE Transactions on Vehicular Technology*, 57(3):1417-1424, (2008).
- [26] Yuan, Y., Zou, W., Zhao, Y., Wang, X., Hu, X. and Komodakis, N., "A robust and efficient approach to license plate detection", *IEEE Transactions on Image Processing*, 26(3):1102-1114, (2017).
- [27] Panahi, R. and Gholampour, I., "Accurate detection and recognition of dirty vehicle plate numbers for high-speed applications", *IEEE Transactions on Intelligent Transportation Systems*, 18(4):767-779, (2017).
- [28] Laroca, R., Severo, E., Zanlorensi, L. A., Oliveira, L. S., Gonçalves, G. R., Schwartz, W. R. and Menotti, D., "A robust real-time automatic license plate recognition based on the YOLO detector", *IEEE International Joint Conference on Neural Networks*, 1-10, (2018).
- [29] Rafique, M. A., Pedrycz, W. and Jeon, M., "Vehicle license plate detection using region-based convolutional neural networks", *Soft Computing*, 22(19):6429-6440, (2018).
- [30] Li, H., Wang, P., and Shen, C., "Toward end-to-end car license plate detection and recognition with deep neural networks", *IEEE Transactions on Intelligent Transportation Systems*, 99:1-11, (2018).
- [31] Bulan, O., Kozitsky, V., Ramesh, P. and Shreve, M., "Segmentation-and annotation-free license plate recognition with deep localization and failure identification", *IEEE Transactions on Intelligent Transportation Systems*, 18(9): 2351-2363, (2017).
- [32] Zhuang, J., Hou, S., Wang, Z., and Zha, Z. J., "Towards Human-Level License Plate Recognition", *In Proceedings of the European Conference on Computer Vision*, 306-321, (2018).