

PAPER DETAILS

TITLE: Bölgesel Tabanlı Evrisimli Sinir Ağları ile Araç Plaka Tanıma

AUTHORS: Talip ÇAY, Emre ÖLMEZ, Orhan ER

PAGES: 10-20

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/2196110>



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Bölgesel Tabanlı Evrişimli Sinir Ağları ile Araç Plaka Tanıma

Talip ÇAY^{a,*}, Emre ÖLMEZ^b, Orhan ER^c

^a Elektrik-Elektronik Mühendisliği ABD, Fen Bilimleri Enstitüsü, Yozgat Bozok Üniversitesi, Yozgat, TÜRKİYE

^b Mekatronik Mühendisliği ABD, Fen Bilimleri Enstitüsü, Yozgat Bozok Üniversitesi, Yozgat, TÜRKİYE

^c Bilgisayar Mühendisliği ABD, Fen Bilimleri Enstitüsü, Bakırçay Üniversitesi, Yozgat, TÜRKİYE

* Sorumlu yazarın e-posta adresi: talip.cay@gmail.com

DOI: 10.29130/dubited.1058850

ÖZ

Bu çalışmada, Bölgesel Tabanlı Evrişimli Sinir Ağları (R-CNN) ile araç plaka lokasyonu belirleme ve belirlenen lokasyon içerisinde plaka okuma işlemi gerçekleştirılmıştır. İki aşamadan oluşan çalışmanın ilk aşamasında giriş görüntülerinden plaka lokasyonları R-CNN ile belirlenirken ikinci aşamada geleneksel görüntü işleme teknikleri ile belirlenen lokasyonlardan plaka okuma işlemi gerçekleştirilmektedir. Çalışmada tasarlanan R-CNN eğitiminde veri setinde bulunan 550 adet görüntünden 450 adedi eğitimde ve 100 adedi test işleminde kullanılmıştır. R-CNN ile plaka lokasyonu bulma işleminde test seti üzerinde %95 başarı oranına ulaşılırken doğru olarak belirlenen lokasyonlardan plaka okuma işleminde %97 başarı oranına ulaşılmıştır.

Anahtar Kelimeler: Görüntü İşleme, Evrişimli Sinir Ağları, Bölgesel Tabanlı Evrişimli Sinir Ağları, Araç Plaka Tanıma

License Plate Recognition with R-CNN

ABSTRACT

In this study, Region Proposals with CNNs (R-CNN) and conventional image processing approaches are used for license plate capture and reading operations respectively. In the first stage of the study, which consists of two stages, plate locations are determined by R-CNN over the input images. In the second stage, conventional image processing techniques are used to read the R-CNN captured license plate locations. In the training and testing phases of the study, 450 of the 550 images in the data set were used in the training and 100 in the testing respectively. As a result, in the process of capturing the plate location with R-CNN, a %95 success rate was achieved on the test set. In the process of reading license plates from correctly determined license plate locations, a success rate of 97% was achieved.

Keywords: Image Processing, Convolutional Neural Networks, CNN, Region Proposals with CNNs, R-CNN, License Plate Recognition

I. GİRİŞ

Yapay zekânın bir alt dalı olan makine öğrenmesi insan zekâsına benzer karar verme eylemlerini gerçekleştirir. Makine öğrenmesi alanında yapay sinir ağları birçok problemin çözümünde sıkılıkla kullanılmıştır. Ancak yapay sinir ağlarının (YSA) durgunluk dönemi olarak adlandırılan dönemde başta donanımsal kısıtlamalar sebebiyle bu alandaki çalışmalar neredeyse durma noktasına gelmiştir. 2000'li yılların başlarında GPU'ların gelişmesiyle birlikte siğ sinir ağlarından derin sinir ağlarına geçiş gerçekleşmiştir.

Derin yapay sinir ağlarının eğitimini ifade eden Derin öğrenme bir makine öğrenmesi sınıfıdır. Derin öğrenme yaklaşımı çoklu soyutlama yapısı ile verinin temsillerini öğrenmek için bir araya getirilmiş çoklu işleme katmanlarında oluşur [1]. Makine öğrenmesi yaklaşımının kalitesi doğru özelliklerin seçimine bağlıdır[2]. Bu özellikleri ortaya çıkarmak için çeşitli önişlemler, boyut indirgeme, özellik seçme vb. işlemler yapılmaktadır. Bu aşamadaki maliyeti azaltmak için özelliklere olan bağımlılıktan kurtulmak gerekmektedir. Sınıflandırıcılar ve diğer tahmin sistemlerini tasarlarken, yapay zekâ ile veriden faydalı bilgiyi (ozellik) çıkarmak daha kolay ve az maliyetli olacaktır[3]. Bu bağlamda derin öğrenme konusu temsili öğrenme ile çok sıkı ilişkilidir. Derin öğrenme algoritmaları özellikle 2005 yılından sonra birçok farklı alana uygulanmıştır[4] [5] [6].

Geleneksel olarak araç üzerinde bulunan sinyal alıcı-verici ile gerçekleştirilen araç tanıma sistemleri görüntü işleme yöntemlerinde yaşanan gelişmeler ile birlikte plaka tanıma sistemlerine evrilmiştir. Derin Öğrenme modelleri ile birçok alanda görüntü işleme çalışmaları bulunmaktadır [7] [8]. Görüntü işlemede çok sayıda görüntüle ile eğitilen derin öğrenme modelleri sonrasında verilen bir görüntü üzerinde gerçekleştirecek işlemi yüksek bir başarı oranı ile gerçekleştirilebilmektedir.

Bu çalışmada gerçekleştirilen plaka tanıma sisteminin ilk aşamasında giriş görüntüsü üzerinde plaka lokasyonunun tespiti için Bölgesel Tabanlı evrişimli sinir ağı kullanılmıştır (R-CNN). Tasarlanan R-CNN mimarisile test seti üzerinde plaka lokasyonu tespitinde %95 başarı oranı elde edilmiştir. Belirlenen plaka lokasyonları içerisinde plaka okuma işleminin gerçekleştirilmesi geleneksel görüntü işleme teknikleri ile yapılmıştır. Renkli olarak elde edilen plaka görseli gri skalaya ardından binary görüntüye çevrilmiş ve bir dizi görüntü işleme tekniği kullanılarak tespit edilen plaka lokasyonları içerisinde %97 doğruluk oranı ile plaka okuma işlemi gerçekleştirilmiştir.

II. LİTERATÜR TARAMASI

Christian Gerber ve Mokdong Chung'in 2016 yılında yayınladıkları makalede evrişimli sinir ağı kullanarak mobil cihazlar için araç plaka tanıma sistemi geliştirmiştir. 88 resim üzerinden test sonuçlarında % 91,25 başarı elde etmişlerdir [9].

M. M. Shaifur Rahman, çalışmasında evrişimli sinir ağı kullanarak plaka karakter tanıma işlemi gerçekleştirmiştir. 1725 karakter ile evrişimli sinir ağını eğitmiştir. İterasyon (epoch) sayısını değiştirerek nihai hata değerini gözlemlemiştir [10].

Kai Tang, 2018 yılında klasik görüntü işleme teknikleriyle ve derin öğrenme modellerinden olan R-CNN, Fast R-CNN ile plaka tanıma işlemi gerçekleştirmiştir ve elde edilen sonuçları karşılaştırmıştır [11].

Lele Xie, Tasweer Ahmad ve Lianwen Jin 2018 yılında yayınladıkları makalede derin öğrenme modellerinden Faster R-CNN ve YOLO ile plaka tanıma işlemi gerçekleştirmiştir. Eğitim için 2049 görüntü kullanılmıştır. Faster R-CNN ile % 85 başarı, YOLO ile % 97 başarı elde edilmiştir [12].

Naaman Omar ve arkadaşları çalışmalarında Fast RCNN ile trafik gözetimi, trafik güvenliği, güvenlik, hizmet amaçları ve park yönetimi için gerçek zamanlı araç plaka sistemi geliştirmiştir. Test aşamasında 100 plaka görüntüsünden % 97'lik bir doğruluk oranı elde etmişlerdir [13].

Puarungroj, Wichai ve Boonsirisumpun, Narong çalışmalarında tek satırlık bir plakadan farklı olarak, iki aşamalı bir eğitim yaklaşımı ve derin öğrenme (MobileNets ve Inception-v3) modelleri kullanmışlardır. İlk olarak her bir plakanın 3 hattını böülümlere ayırarak ve eğitmişlerdir. İkinci adımda, tabaktaki Tay harfleri ve sayıları böülümlere ayrılmış ve eğitilmiştir. Test sonuçlarında doğruluk oranı sırasıyla % 96.94 ve % 91.76 bulunulmuştur [14].

Emre ÇAMAŞIRÇIOĞLU, YSA ve görüntü işleme teknikleri kullanarak araç plaka tanıma sistemi geliştirmiştir. Bu uygulamada plaka konumu klasik YSA kullanılarak bulunmuş, eğik düzensiz görseller için radon dönüşümü kullanılmıştır. Karakter tanıma işleminde aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır [15].

İsmail IRMAKÇI, çalışmasında öncelikle görüntüye önişlem uygulamış, görüntüden plaka çıkarımı için morfolojik görüntü işleme teknikleri uygulanarak köşelerin kapladığı en küçük dörtgen bölge görüntüden çıkarılmıştır. Çıkarılan bölgeye tekrar önişlemler uygulandıktan sonra bölge tekrar karakter ayrıştırma sisteminde yatay ve düşey taramaya sokulmuştur. Son olarak karakterlerin tanımásında yapay sinir ağı kullanılarak plakaların ASCII kodu tespit edilmiştir [16].

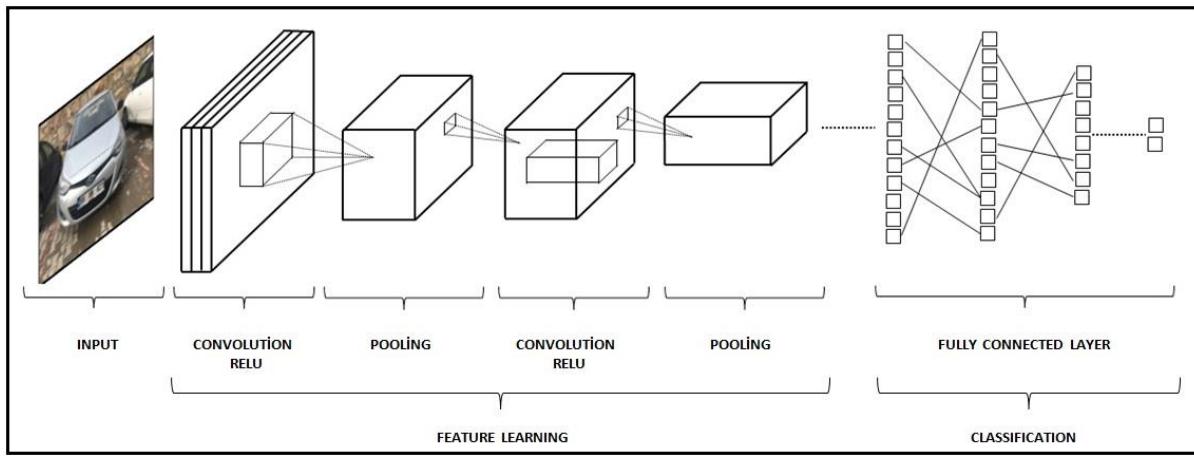
Naga Surya Sandeep Angara, yapılan çalışmasında derin öğrenme yöntemleri kullanılmıştır. Kesilmiş plaka sinir ağına sokularak karakterleri bulunmuştur. Bulunan karakterler görüntü işleme teknikleri ile tanınmıştır. Sinir ağıının eğitimi sırasında aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanılmıştır. Ağ Eğitimi için 9324 veri, test için 2318 veri kullanılmıştır [17].

Hogne Jongensen, çalışmasında R-CNN, CNN, ve YOLO ile araç plaka konumunu belirlemiştir ve % 98,9 başarı elde etmiştir. Ağ eğitimi için 30 adet katmanla yapılmış ve eğitim için 410 adet, test için 100 araç plaka görüntüsü kullanılmıştır. Aktivasyon fonksiyonu ReLU fonksiyonuyla çalışmıştır [18].

Ali BAKKALOĞLU, yapılan çalışmasında görüntü işlem teknikleri kullanarak hareketli araçlardan alınan 640x480 boyutundaki görüntüler üzerinde araç plaka tanıma işlemi yapmıştır. Test için 1500 görüntü kullanılmıştır. Bazı kenar bulma filtreleri kullanılmış ve OTSU'nun metodu ile gri tonlu görüntünden siyah beyaz görüntüye dönüşüm için eşik değeri hesaplamaları yapılmıştır [19].

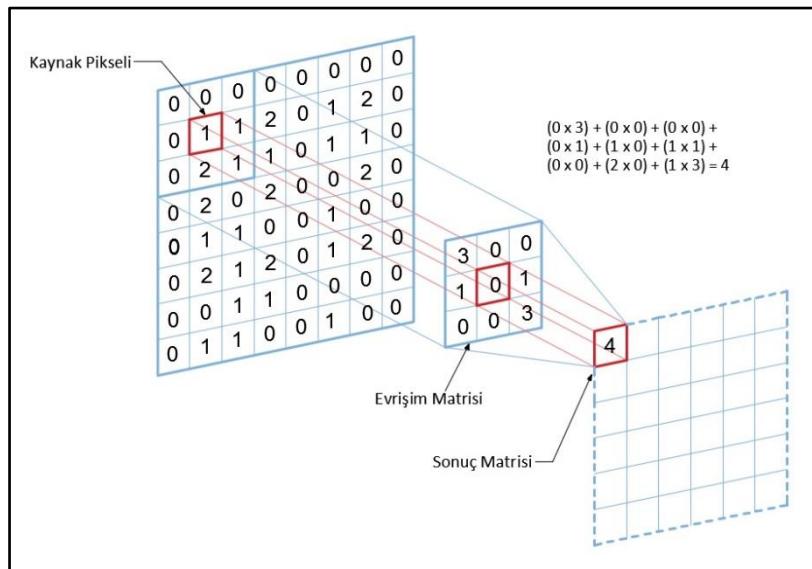
III. EVRİŞİMLİ SINİR AĞLARI (CONVOLUTIONAL NEURAL NETWORK)

Hayvan görsel korteks yapısından esinlenilerek tasarlanan Evrişimli sinir ağları (ESA) bir çeşit yapay sinir ağı mimarisidir [20]. Geleneksel yapay sinir ağı mimarilerinde her bir sinir hücresi bir sonraki katmanda bulunan her bir sinir hücresi ile bağlantılı şekilde çalışırken ESA'da ağırlık paylaşımı yapıldığından parametre sayısı ve işlem yükü klasik yapay sinir ağlarına göre ciddi oranda azaltılmaktadır. Bu özellikleri ile ESA mimarisi bilgisayarlı görü alanında geleneksel yöntemlerden çok daha etkili olmuş ve daha iyi performans sergilemiştir. ESA Nesne algılama, görüntü işleme, segmentasyon, doğal dil işleme, video analizi gibi birçok alanda başarılı sonuçlar vermektedir [21]. Şekil 1'de görüleceği üzere ESA mimarisi evrişim (convolution), ortaklama (pooling), aktivasyon ve sınıflandırmanın yapıldığı tam bağlantılı katmanlardan (fully connected layers) oluşmaktadır.



Sekil 1. Evrişimli Sinir Ağı.

Dijital görüntüler, belirli sayısal değerlere karşılık gelen piksellerden oluşmaktadır. ESA'da dijital görüntüler üzerinden özellik çıkarma işlemi görüntü üzerinde iki boyutlu filtrelerin evrişim (convolution) işlemine tabi tutulmasıyla gerçekleştirilmektedir. Görüntü üzerinden çıkarılacak olan özellikler; renk tonu, ışık açısı, şekil, boyut vb. olabilir. Şekil 2'de 8×8 boyutundaki giriş görüntüsü üzerinde 3×3 'luk filtre matrisi ile evrişim işlemi uygulanmıştır. Filtre matrisi giriş görüntüsünün üzerinde belirli bir adım büyüklüğü ile ilerlerken karşılıklı olarak eşleşen piksellerin çarpımlarının toplamı alınarak evrişim işleminin sonucu sonuç matrisine yazılır. Evrişim işleminin matematiksel ifadesi aşağıda eşitlik 1'de gösterilmektedir. Giriş görüntüsü f ile filtre matrisi h 'ın evrişim işlemi sonucu olarak G sonuç matrisi elde edilmiştir.



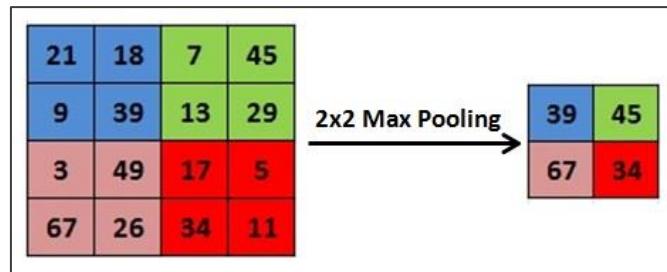
Sekil 2. Evrişim İşlemi.

$$G[m, n] = (f * h)[m, n] = \sum_j \sum_k h[j, k] f[m - j, n - k] \quad (1)$$

ESA'da her evrişim katmanından sonra bir aktivasyon katmanı bulunmaktadır. Yapay sinir ağlarında aktivasyon fonksiyonunun kullanılmasının nedeni sistemi doğrultuktan çıkarmaktır. ESA'da en çok kullanılan aktivasyon fonksiyonlarından biri ReLU fonksiyonudur. Aşağıda denklem 2'de verilen ReLU fonksiyonu hızlı türevlenebilir bir aktivasyon fonksiyonu olması dolayısıyla derin yapay sinir ağlarında sıkça tercih edilmektedir. ReLU fonksiyonu girişinin 0'dan küçük ve eşit olduğu durumlarda çıkış değeri olarak 0 değerini üretirken diğer durumlarda giriş değerini çıkışa aktarır.

$$ReLU(x) = \max(x, 0) \quad (2)$$

ESA'da evrişim ve aktivasyon (ReLU) katmanından sonra ortaklama (pooling) katmanı bulunmaktadır. Ortaklama katmanın kullanılmasının nedeni parametre sayısını azaltarak aşırı öğrenmenin önüne geçmek ve işlem yükünü azaltmaktadır. Bu durum giriş özellik sayısının oldukça fazla olduğu görüntü işleme problemlerinde istenen bir durumdur. Şekil 3'de 2x2 boyutunda bir filtre ile maksimum ortaklama işleminin gerçekleştirilmesi gösterilmektedir. Şekil 4'te 2x2'lik filtre ile ortaklama yapılan görselin boyutu küçülürken kabaca özelliklerini koruduğu görülmektedir.



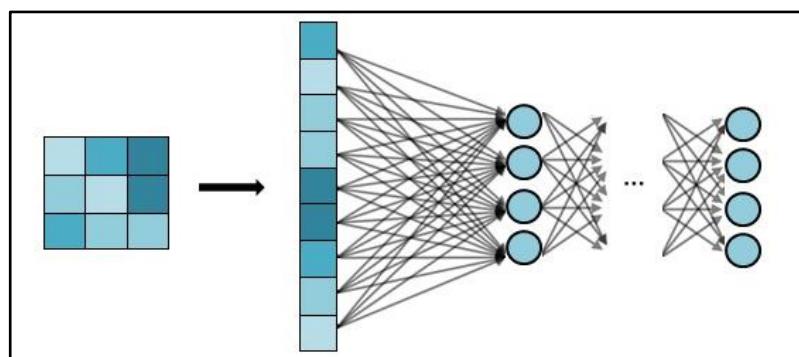
Şekil 3. Maksimum Ortaklama İşlemi.



Şekil 4. 2x2 Boyutunda Bir Filtre ile Maksimum Ortaklama.

ESA'da çıkarımının yapıldığı katman tam bağlantılı katman olarak adlandırılır. Şekil 5'te görüldüğü gibi evrişim, ReLU ve ortaklama katmanlarının son çıkışı olan iki boyutlu özellik haritası sütun matrisine dönüştürülerek sınıflandırma işlemi gerçekleştirilmektedir. Tam bağlantılı katmanda her bir sinir hücresi bir sonraki katmandaki tüm sinir hücresi ile ilişkilidir. Tam bağlantılı katmanın çıkışında sınıf değerlerini belirginleştirmek için genellikle softmax fonksiyonu kullanılmaktadır. Denklem 3'te softmax fonksiyonunu görülmektedir. Softmax fonksiyonunun çıkışı 0 ile 1 arasında değişen bir olasılık değeri vermektedir.

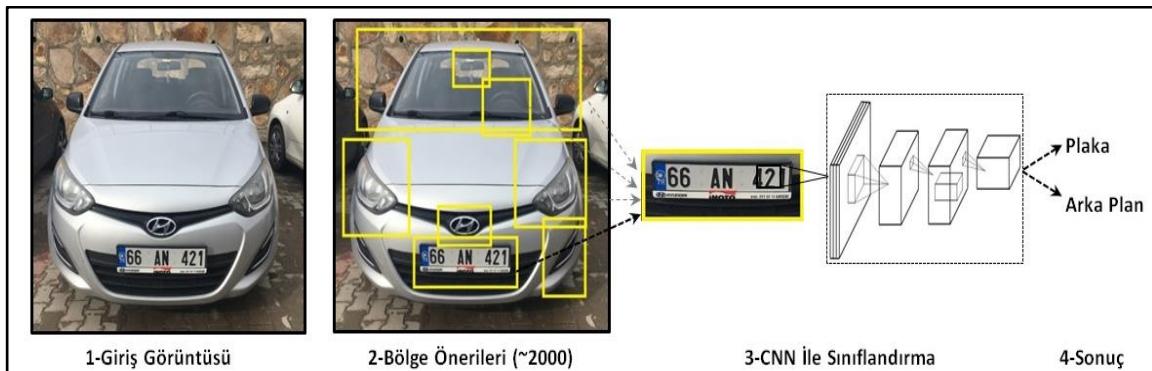
$$\text{softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (3)$$



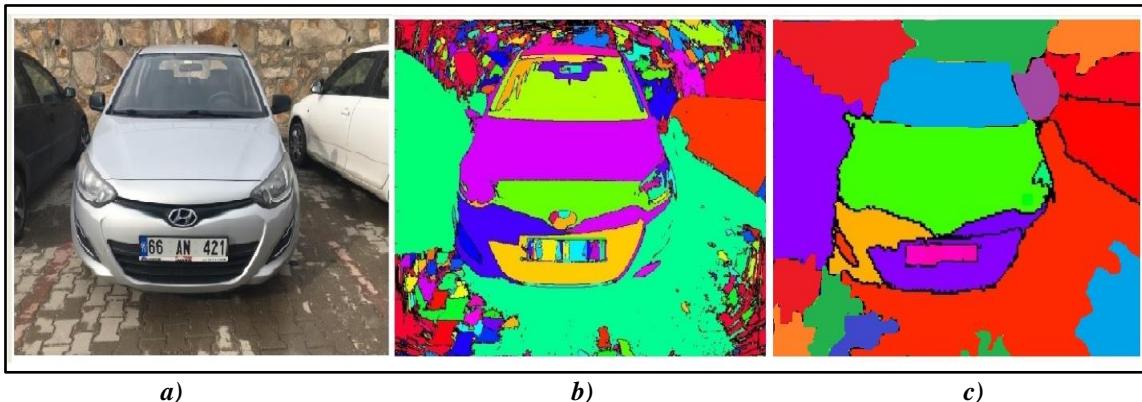
Şekil 5. Tam Bağlantılı Katman.

A. BÖLGESEL TABANLI EVRİŞİMLİ SİNİR AĞLARI (R-CNN)

R-CNN verilen bir giriş görüntüsü üzerinde çıkarılan bölge önerilerini (~2000 bölge) sınıflandırarak, sınıflandırma problemini bir nesne tespit problemine dönüştürmüştür [22]. R-CNN'de giriş görüntülerinden bölge seçme işlemi bir seçici arama (selective search) algoritması ile gerçekleştirilmektedir. Seçici Arama algoritmasında şekil 6 a'da görülen giriş görüntüsü şekil 6 b'de görüldüğü gibi bölgeler oluşturmak için alt segmentasyonlara ayrılır. Son olarak renk benzerliği, doku benzerliği, boyut benzerliği ve şekil uyumluluğuna bakılarak benzer bölgeler bir greedy algoritması ile belirli bir iterasyonla birleştirilerek şekil 6 c'deki nihai segmentasyon elde edilir. Nihai segmentasyona göre belirlenen bölgeler bölge önerisi olarak ESA'da sınıflandırılır [23].



Şekil 5.R-CNN Çalışması.



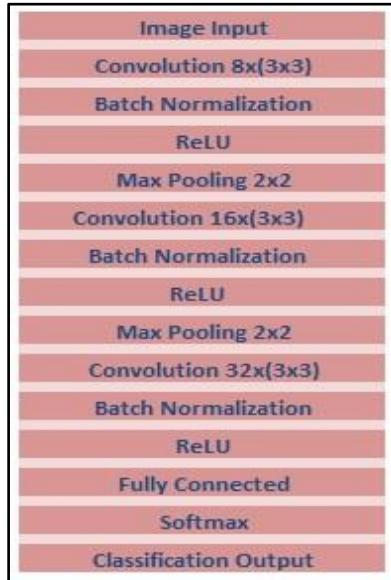
Şekil 6. Görüntü Segmentasyonu.

IV. PLAKA TANIMA SİSTEMİ

Bu çalışmada gerçekleştirilen plaka tanıma sistemi çalışması iki aşamadan oluşmaktadır. İlk olarak giriş görüntülerini üzerinde R-CNN ile plaka lokasyonları belirlenirken ikinci aşamada belirlenen lokasyondaki plakanın geleneksel görüntü işleme yöntemleri kullanılarak okunması gerçekleştirilir. Çalışmada 550 adet görüntünün oluşan veri setinin 450 adedi R-CNN eğitimi için kullanılırken 100 adedi test işlemleri için kullanılmıştır.

A. PLAKA LOKASYONU BELİRLEME

Şekil 7'de plaka tanıma sisteminin ilk aşaması olan plaka konum tespiti için kullanılan R-CNN mimarisi görülmektedir. Mimaride sırasıyla 8, 16 ve 32 adet 3x3 boyutunda filtrelerle gerçekleştirilen evrişim katmanlarını, normalizasyon katmanları, ReLU katmanları ve 2x2 filtre ile gerçekleştirilen maksimum ortalama katmanları takip etmektedir. Tasarlanan mimaride giriş katmanı dahil toplam 15 adet katman bulunmaktadır.



Şekil 7. R-CNN Mimarisi.

Aşağıda şekil 8'de eğitimi tamamlanmış olan R-CNN modelinin test seti içerisindeki bir görüntü üzerinde elde ettiği sonuç görülmektedir. İlgili görüntü üzerinde model plaka lokasyonunu başarılı bir şekilde tespit etmiştir.



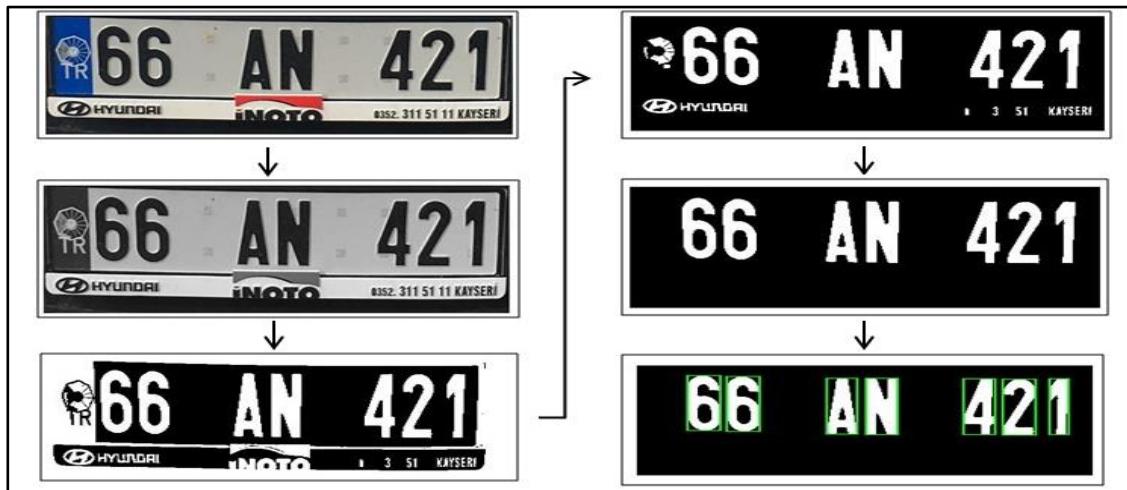
Şekil 8. R-CNN ile bulunan plaka konumu.

B. PLAKA OKUMA

B. 1 Plaka Karakterlerinin Çıkarılması

Plaka lokasyonunun tespitinden sonra Şekil 9'da görüleceği üzere plaka görüntüsü giriş görüntüsü üzerinden kesilip alınarak 240x360 piksel boyuta indirgenmiş ve çeşitli görüntü işleme teknikleri ile

karakterlerine ayrıstırılmıştır. Burada ilk olarak RGB (Red-Green-Blue) olarak alınan görüntü, gri skala görüntüye çevrilmiş ardından otsu metoduyla otomatik olarak 0-1 arasında belirlenen threshold değeriyle binary görüntüye dönüştürülmüştür [24]. Daha sonra 550 piksel büyülüğünden küçük nesneler görüntü içerisinde temizlenmiş ve görüntü üzerinde sadece plaka karakterleri kalmıştır.



Şekil 9. Tespit Edilen Plaka Görüntünün Görüntü İşleme Teknikleri İle Karakterlere Ayrılması.

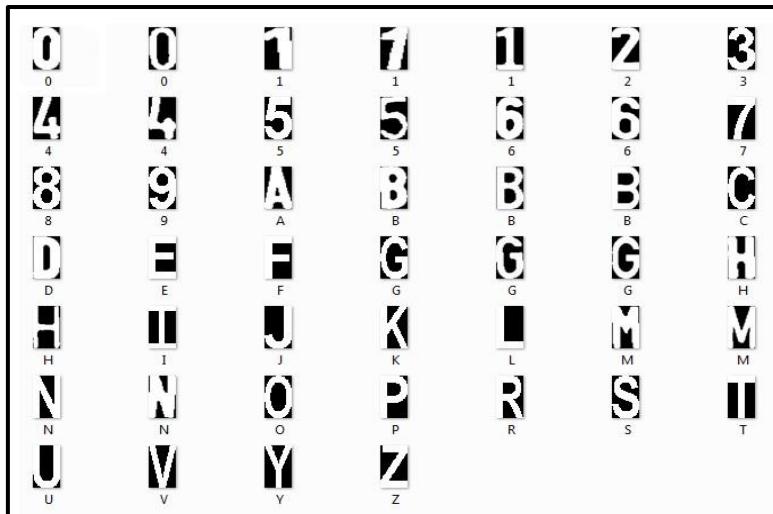
B. 2 Plaka Karakterlerinin Okunması

Korelasyon, iki ya da daha çok sayıda sürekli değişken arasındaki ilişkiyi göstermekte, ilişki miktarı ise korelasyon katsayısı ile belirlenmektedir. Bu çalışmada plaka karakterlerini okumak için istatistiksel korelasyon katsayısı olarak bilinen Pearson korelasyon katsayısı kullanılmıştır. İki değişken arasındaki doğrusal ilişkinin derecesini belirleyen korelasyon katsayısı, r ile gösterilmektedir [25]. Pearson korelasyon katsayısı hesabı aşağıda denklem 4'te gösterildiği gibidir;

$$r = \frac{s_{xy}}{s_x s_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) / (n-1)}{s_x s_y} \quad (4)$$

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad s_x = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (5)$$

Şekil 9'daki karakterlere indirgenmiş plaka görüntüsünden alınan karakterler ile şekil 10'daki harf ve rakamlardan oluşan karakterler arasındaki korelasyon katsayısı hesaplanmıştır. Denklem 4'teki korelasyon katsayısı (r) +1 ile -1 arasında değişmektedir. Eğer korelasyon katsayısı +1'e yakınsa karakterler arasında ilişki yüksektir, katsayı değeri -1'e yakınsa bir ilişki yoktur. Korelasyon hesabındaki ana amaç plaka karakterleri ile şekil 10'daki karakterler arasındaki benzerliğin belirlenmesidir. Örneğin şekil 9'daki plaka görüntünün ilk karakteri 6 ile şekil 10'daki 46 karakterin her biri ile ayrı ayrı korelasyon katsayı hesabı yapıldıktan sonra en yüksek katsayıya sahip karakterin indeks değeri sonuca yansımaktadır. Bu işlem plaka karakterlerinin her biri için sırasıyla uygulanmaktadır.



Şekil 10. Korelasyon İşlemine Alınan Harf ve Rakamlar.

V. ARAŞTIRMA BULGULARI

Bu çalışmada sonuçların değerlendirilmesi ve başarı hesabı çalışmanın iki ayrı aşaması için ayrı ayrı gerçekleştirilmiştir. Test seti üzerinde plaka lokasyonu tespitinde %95 başarı oranına ulaşılırken belirlenen plaka lokasyonlarından plaka okuma işleminde %97'lik bir başarı oranına ulaşılmıştır.

Tablo 1. Performans Kriterleri.

Eğitim Veri Seti Görüntü Sayısı	450
Test Veri Seti Görüntü Sayısı	100
	Doğruluk (%) Hata Oranı (%)
Plaka Lokasyon Bulma	95 5
Plaka Okuma	97 3

VI. SONUC

Yapay zekâ yöntemleri görüntü sınıflandırma, nesne algılama, tıp, doğal dil işleme gibi birçok alanda kullanılmaktadır. Günümüzde görüntü işleme teknikleri kullanılan araç plaka tanıma sistemleri; trafik kontrolü, toplu konut giriş çıkışları, sınır bölgeleri, üniversiteler ve otoparklar gibi birçok yerde kullanılmaktadır.

Bu çalışmada, evrişimli sinir ağı modellerinden R-CNN modeli kullanılarak araç plaka tanıma işlemi gerçekleştirilmiştir. Çalışmada kullanılan 550 adet araç görüntüsünden oluşan veri setinin 450 adedi eğitim 100 adedi test işlemlerinde kullanılmıştır. Çalışma iki aşamada gerçekleşmiş; ilk aşamada tasarlanan R-CNN'in 450 adet görüntü ile eğitimi gerçekleştirilerek test seti üzerinde plaka lokasyonu tespiti gerçekleştirilmiştir. İkinci aşamada doğru olarak tespit edilen plaka lokasyonları üzerinden plaka okuma işlemi gerçekleştirilmiştir.

İleride yapılacak çalışmalarla bölüm 3'te verilen doğruluk oranı ve algoritma hızını artırmak için Fast-RCNN ve Faster RCNN gibi evrişimli sinir ağları modellerinin yanı sıra YOLO gibi farklı modellerin denenmesi düşünülmektedir. Ayrıca eğitim için kullanılan veri setinin artırılması da yine başarı oranının artmasına katkı sağlayacaktır.

V. KAYNAKLAR

- [1] Yann le Cunn, "A theoretical framework for Back-Propagation," *Connect. Model. Summer Sch.*, no. 22–21, 1988, Accessed: Jan. 20, 2021. [Online]. Available: <http://yann.lecun.org/exdb/publis/pdf/lecun-92b.pdf>.
- [2] C. Hacıoğlu, "Derinlikli Öğrenme Kullanılarak Konuşmadan Uykululuk/uykusuzluk Tespiti," Yüksek Lisans Tezi, Elektronik ve Haberleşme Mühendisliği, Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, Türkiye, 2014.
- [3] S. Zhou, Q. Chen, and X. Wang, "Convolutional deep networks for visual data classification," *Neural Process. Lett.*, vol. 38, no. 1, pp. 17–27, 2013.
- [4] A. Şeker, A. Diri ve H. Balık, "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme" *Gazi Mühendislik Bilimleri Dergisi*, c. 3, s. 3, ss. 47-64, 2017.
- [5] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural networks*, vol. 61, pp. 85-117, 2015.
- [6] A. Voulodimos, A. Doualamis, N. Doualamis and E. Protopapadakis, "Deep learning for computer vision: A brief review," *Computational intelligence and neuroscience*, 2018.
- [7] Ö. Inik, E. Ülker, "Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri," *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, c. 6, s. 3, ss. 85-104, 2017.
- [8] T. H. Chan, K. Jia, S. Gao, J. Lu, Z. Zeng and Y. Ma, "A simple deep learning baseline for image classification?," *IEEE transactions on image processing*, vol. 24, no. 12 , pp. 5017-5032, 2015.
- [9] C. Gerber and M. Chung, "Number plate detection with a multi-convolutional neural network approach with optical character recognition for mobile devices," *J. Inf. Process. Syst.*, vol. 12, no. 1, pp. 100–108, 2016.
- [10] M. S. Rahman, M. S. Nasrin, M. Mostakim, and M. Z. Alom, "Bangla License Plate Recognition Using Convolutional Neural Networks (CNN)," 2019, arXiv:1809.00905.
- [11] K. Tang, "Chinese license plate recognition," Master thesis, Department of Electrical Engineering, University at Buffalo, New York, USA, 2018.
- [12] L. Xie, T. Ahmad, L. Jin, Y. Liu, and S. Zhang, "A new CNN-based method for multi-directional car license plate detection," *IEEE Trans. Intell. Transp. Syst.*, vol. 19, no. 2, pp. 507–517, 2018.
- [13] N. Omar, A. Mohsin Abdulazeez, A. Sengur, and S. G. Saeed Al-Ali, "Fused faster RCNNs for efficient detection of the license plates," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 19, no. 2, p. 874, 2020.
- [14] W. Puarungroj and N. Boonsirisupun, "Thai license plate recognition based on deep learning," *Procedia Comput. Sci.*, vol. 135, pp. 214–221, 2018.
- [15] E. Çamaşiroğlu, "Araç Plakası Algılama ve Tanıma," Yüksek Lisans Tezi, Elektronik Mühendisliği, Fen Bilimleri Enstitüsü, Ankara Üniversitesi, Ankara, Türkiye, 2007.

- [16] I. Irmakçı, "Otomatik araç plaka tanıma sistemi," Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği, Fen Bilimleri Enstitüsü, Ege Üniversitesi, İzmir, Türkiye, 2008.
- [17] N. S. S. Angara, "Automatic License Plate Recognition Using Deep Learning Techniques," Master's thesis, Department of Electrical Engineering, The University of Texas at Tyler, Texas, USA, 2015.
- [18] H. Jørgensen, "Automatic License Plate Recognition using Deep Learning Techniques," Master's thesis, Master of Science in Computer Science, Norwegian University of Science and Technology, Trondheim, Norway 2017.
- [19] A. Bakkaloğlu, "Araç Plaka Tanıma Sistemi," Yüksek Lisans Tezi, Bilgisayar Mühendisliği, Fen Bilimleri Enstitüsü, Selçuk Üniversitesi, Konya, Türkiye, 2011.
- [20] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097-1105, 2012.
- [21] F. G. Tan, A. S. Yüksel, E. Aydemir ve M. Ersoy, "Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme," *Avrupa Bilim ve Teknoloji Dergisi*, s. 25, ss. 159-171, 2021.
- [22] R. Girshick, "Fast r-cnn," In *Proceedings of the IEEE international conference on computer vision*, pp. 1440-1448, 2015.
- [23] J. R. Uijlings, K. E. Van De Sande, T. Gevers and A. W. Smeulders, "Selective search for object recognition," *International journal of computer vision*, vol. 104, no. 2, pp. 154-171, 2013.
- [24] N. Otsu, "A threshold selection method from gray-level histograms." *IEEE Transactions on Systems, Man, and Cybernetics*. vol. 9, no. 1, pp. 62–66, 1979.
- [25] S. Şengin ve Z. Aşan, "Bulanık mantıkta korelasyon katsayısı; meterolojik olaylarda bir uygulama," *Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, c. 20 s. 1, ss. 151-161, 2007.