

Örnek Bölütlemesi ile Nesne ve Renk Sınıflandırması

Ahmet ÖZCAN*¹ , Ömer ÇETİN¹ 

¹Milli Savunma Üniversitesi, Hezârfen Havacılık ve Uzay Teknolojileri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul, Türkiye

(Alınış / Received: 15.11.2021, Kabul / Accepted: 16.03.2022, Online Yayınlanma / Published Online: 20.04.2022)

Anahtar Kelimeler

Renk tespiti,
Örnek bölütlemesi,
Evrişimsel ağlar,
Makine öğrenmesi

Özet: Görüntü üzerinde nesne tespit ve sınıflandırma uygulamaları görüntü işleme alanında ele alınan temel konulardandır. Otonom araçlar ve görsel takip sistemleri gibi popüler uygulamalarda ihtiyaç duyulan nesne tespit ve sınıflandırma işlemlerinin gerçekleştirilmesinde evrişimsel sinir ağları, hesaplama performansı (hızı) ve başarımı ile öne çıkmaktadır. Ancak nesne tespit ve sınıflandırma işlemleri aynı tip nesnelerin renk gibi farklı özellik çıkarımlarından yoksun olmaktadır. Bu durumun temelinde ise nesne tipi aynı olsa da her bir rengin yeni bir sınıf olarak ağa tanıtılması gerekliliğidir. Tespit edilen nesnenin renk bilgisini edinmenin bir diğer yolu ise nesneye ait görüntüyü piksel seviyesinde işlemektir. Piksel seviyesinde yapılacak işlemlerin doğruluğunu arttırmak için nesne tespitinin yanında bölütme işlemi de yapılarak tespit edilen nesnenin sınırlarını net olarak belirlemek gereklidir. Tespit edilen nesnenin rengi tespit edilen nesne sınırları içerisindeki piksel yoğunluk değerleri ile sınıflandırılabilir. Bu çalışmada evrişimsel sinir ağları ile gerçekleştirilen örnek bölütlemesi sonrası piksel bilgilerine dayalı renk sınıflandırması yapılarak nesnelerin sınıflarının yanı sıra renkleri de tespit edilebilmiştir. Ortaya konulan yaklaşımın başarısı deneysel olarak sınanmış ve etkin bir yöntem sunularak literatüre katkıda bulunulmuştur.

Object and Color Classification with Instance Segmentation

Keywords

Color detection
Instance segmentation,
Convolutional networks,
Machine learning

Abstract: One of the main issues in the computer vision field is the applications of object detection and classification. Convolutional neural networks stand out due to its computational performance (speed) and accuracy to realize object detection and classification processes needed in popular applications such as autonomous vehicles and surveillance systems. However, object detection and classification processes lack different feature extractions like the colors of the same types of objects. The reason behind this is each color is required to be defined as a new class in the network even if the object category is the same. Another way to obtain the color data of the detected object is to process the related image at the pixel level. In order to improve the accuracy of the methods to be performed at the pixel level, it is necessary to clearly define the boundaries of the detected object by using segmentation as well as object detection. The color of the object can be classified with the pixel intensity values of the image in detected object boundaries. In this study, after the instance segmentation is carried out with convolutional neural networks, color classification based on pixel information is performed and the colors of the objects is determined as well as their classes. The success of the proposed approach has been tested experimentally and contributed to the literature by presenting an effective method.

1. Giriş

Görüntü işleme ve bilgisayar görüşü açısından ele alındığında görüntü bölütleme (segmentasyon), bir sayısal görüntüyü birden çok bölüme (görüntü nesneleri olarak da bilinen piksel kümelerine) ayırma

işlemi olarak tanımlanabilir. Bu işlemin amacı, bir görüntünün temsilini basitleştirmek ve/veya daha anlamlı bir temsil şeklinde sunum haline getirerek analizini daha kolay duruma dönüştürmektir. Görüntü bölütleme genellikle görüntüde yer alan nesneleri tespit etmek ve birbirlerinden ayrıldıkları sınırları

*İlgili yazar: iletisim@ahmetozcan.com

(çizgiler, eğriler vb.) bulmak amacıyla kullanılır. Diğer bir ifade ile bölütleme aynı nesneye ait görüntüdeki piksellere ortak bir etiket atama çabasıdır.


Nesne tespit ve sınıflandırma uygulamaları, otonom araçların çevresel farkındalığının sağlanması, görüntü işleme tabanlı tespit ve teşhis sistemlerinin oluşturulması gibi yeni nesil teknolojilerde yaygın olarak faydalanılan ve üzerinde çalışılan yaygın araştırma konularındandır [1]. Özellikle gerçek zamanlı çalışma ihtiyacı duyulan uygulamalarda nesne tespit ve sınıflandırma işlemlerinin gerçekleştirilmesinde etkin olarak derin öğrenme yöntemleri kullanılmakta, benzer işleve sahip diğer tekniklere istinaden hesaplama performansı (hızı) ve nesne tespit başarısı ile bu yöntemin öne çıktığı görülmektedir [2-5].

Görüntüde yer alan nesnelerin birbirlerinden ayrılması ve nesnelere ait piksellerin gruplanması için görüntü bölütleme yöntemlerinden, bu nesnelerin etiketlenmesi ve adlandırılması amacıyla da yaygın olarak derin öğrenme yöntemleri arasında yer alan evrimsel sinir ağlarından yararlanılmaktadır [6]. Evrimsel sinir ağlarının her geçen gün kullanım alanı bu nedenlerle giderek genişlemektedir.


Nesne tespit ve sınıflandırma işlemleri genellikle nesnelerin renk gibi farklı özelliklerinden yoksun olarak gerçekleştirilmektedir. Örneğin nesne tespit ve sınıflandırma yaklaşımları ile sayısal bir görüntü üzerinde yer alan arabaların bulunmasına yönelik literatürde çok sayıda çalışmaya [7-8] rastlamak mümkünken, tespit edilen arabaların renklerinin çıktı olarak üretilebildiği hatta sadece belirli bir renkte araçların tespit edilmesine yönelik gerçekleştirilen çalışmalara rastlamak çok daha nadirdir [9].

Renk bilgisine göre sınıflandırma yapabilmek için en temel yaklaşım kullanılan ağın aynı nesneye ait farklı renklerde veri içeren veri setleri ile ayrı ayrı eğitilmiş olmasıdır. Böylece aynı nesnenin farklı renklerdeki varyasyonları artık evrimsel sinir ağı için birbirlerinden farklı etiketler alabilen renkli görüntü bileşenleri haline gelecektir. Ancak, bu yaklaşım her ne kadar teoride uygulanabilir olsa dahi pratikte çeşitli zorluklarla karşılaşmaktadır. Çünkü bir nesnenin doğada hangi renklerde bulunabileceği oldukça geniş bir değer aralığı alabilmektedir. Tüm bu farklı renk seçeneklerini içeren çok sayıda nesne için bir eğitim seti üretilmesi gerekmektedir. Ayrıca evrimsel sinir ağının bu tip bir veri seti ile eğitilmesi zaman maliyeti açısından oldukça yüksek bir sonuca sebebiyet vermektedir. Bu yöntemde veri setinin oluşturulması aşamasında aynı nesneye yönelik farklı renklerdeki verilerin gerekliliği ve etiketlenmesi başlı başına bir zorluk olarak karşımıza çıkmaktadır. Bu zorluk aşılsa bile tanımlanabilen renklerin kısıtlı kalacağı düşünülebilir. Bu sebepten ötürü öncelikle nesnenin tespit edilip sonrasında nesnenin renginin tespit edilmesi sinir ağının eğitim sürecinde ek yük


getirmeyecektir. Ayrıca renk tespiti konusunda yapılacak çalışmalarda da farklı renkler ve renk grupları için tanımlamalar yapılarak probleme özel çözümler de geliştirilebilir.



(a)



(b)



(c)

Şekil 1. (a) Sayısal görüntü, (b) anlamsal bölütleme ve (c) örnek bölütlemesi [10]

Tespit edilen nesnenin renk bilgisi özelliğini edinmenin bir diğer yolu ise nesneye ait görüntünün piksel seviyesinde renk bilgilerini işlemektir. Ancak bu yöntemin etkin olarak işleyebilmesi için ilk olarak piksel seviyesinde yapılacak işlemlerin doğruluğunu arttırmak amacıyla nesne tespitinin yanında hassas bir bölütme işlemi de yapılarak tespit edilen nesnenin sınırlarının net biçimde ortaya konulması gerekmektedir. Aksi takdirde nesneye ait olmayan piksel değerleri renk kararını olumsuz olarak kolaylıkla etkileyebilecektir. Belirlenen nesne sınırları içerisindeki piksel bilgilerinden yola çıkılarak nesnenin rengi sınıflandırılabilir. Ancak bu yöntemin bir diğer ihtiyacı da kümeleme işlemi sonrasında elde edilen nesneye ait en yoğun renk değerinin tespit edilmesidir.

Bu çalışmada evrimsel sinir ağları ile gerçekleştirilen örnek bölütlemesi sonrası piksel bilgilerine dayalı renk sınıflandırması yapılarak nesnelerin sınıflarının yanı sıra renklerinin de tespit edilebilmesi

sağlanmıştır. Çalışmanın ikinci bölümünde, ortaya konulan yaklaşımın gerçekleştirilmesi esnasında faydalanılan yöntemler bir süreç dahilinde tanımlanmıştır. Bir sonraki bölümde, yaklaşımın başarısı sınanmış ve sonuçlar irdelenmiştir. Son bölümde ise çalışma kapsamında geliştirilen yaklaşımının sağladığı avantajlar ile potansiyel kullanım alanlarına değinilerek hem bu konu üzerinde yapılabilecek çalışmalar hem de yaklaşımın benzer bilgi çıkarımlarına yönelik uygulanabilirliği ortaya konulmuştur.

1.1 Literatür özeti

Literatür incelendiğinde, sayısal bir görüntü üzerinde yer alan nesnelerin bölgelerinin belirlenmesi işleme bölütleme (segmentation) adı verildiği görülmektedir [6]. Görüntü bölütleme işlemi; anlamsal (semantic) ve örnek (instance) olarak iki alt alana ayrılabilir [11]. Genellikle sayısal görüntü üzerinde nesne tespiti uygulamalarında görüntüdeki nesneler ayrı ayrı tespit edilmeye çalışılır ve her biri ayrı bir minimum çevreleyen çerçeve içerisine alınarak birbirlerinden ayrılmaya çalışılmaktadır. Anlamsal bölütlemeye bağlantılı nesne gruplarına istinaden ortak bölgeler belirlenmektedir. Örnek bölütlemesinde ise her bir nesnenin bölgesi bağımsız olarak belirlenir.

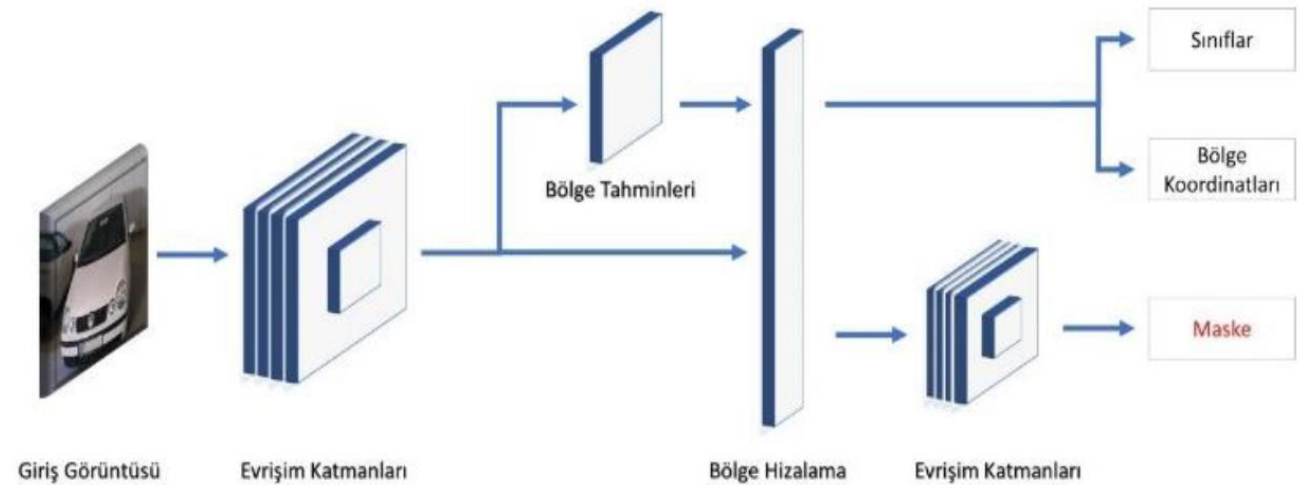
Örneğin Şekil 1'de yer alan üç farklı görüntü incelendiğinde, aynı sayısal görüntü üzerinde uygulanmış anlamsal bölütleme ve örnek bölütlemesi işlemlerinin farkları görülebilmektedir. Şekil incelendiğinde, çalışma kapsamında etkin olarak faydalanılacak yaklaşımın örnek bölütlemesi olduğu görülmektedir. Burada her bir nesne ayrı ayrı tanımlanmış ve bölgeleri ortamdaki net biçimde ayırt edilebilmiştir.

Örnek bölütlemesi konusunda literatür incelendiğinde farklı uygulama yaklaşımları olduğu

görülebilmektedir [12-15]. Çalışma kapsamında Tablo 1 ile gösterilen yaygın kullanımı olan örnek bölütleme yöntemleri incelenmiş ve karşılaştırılmıştır. Bunlar arasından, Facebook yapay zekâ ekibi tarafından önerilen Mask R-CNN gerçekleştirilen çalışmalarda yaygın olarak tercih edilen yaklaşım olarak ön plana çıkmaktadır [13]. Alışıl gelmiş nesne tespiti yanında tespit edilen nesneyi içeren çerçeve için maske oluşturarak bölütlemeyi gerçekleştiren Mask RCNN'in basit ve etkili nesne bölütlemesi sunması bu yöntemin seçilmesinde etkili olmuştur.

Mask R-CNN yaklaşımına bakıldığında temelinde RESNET101 ve RESNEXT101 evrimsel ağları ile nesne tespiti bulunduğu görülmektedir [13]. Yaklaşımında görüntünün tamamına bölütleme işlemi yapmak yerine öncelikle nesne olması muhtemel alanlar (region of interest-ROI) tespit edilir. Sonrasında bu alanlar içerisinde nesne sınıflandırması ve bölütleme yapılarak maske çıkarılması işlemleri Şekil 2 ile gösterilen biçimde paralel olarak gerçekleştirilir [17].

Derin öğrenme yaklaşımları ile nesnelerin sınıflandırılması ve bölütlenmesinde ihtiyaç duyulan bir diğer kritik konu ise veri setleridir. Tablo 2 ile literatürde faydalanılan farklı veri setleri karşılaştırmalı olarak değerlendirilmiştir. Veri setleri arasında yer alan MS-COCO veri seti nesne tespit ile bölütlemesi alanında derin öğrenme yaklaşımlarının geliştirilmesi ve sınanmasında sıklıkla kullanılan bir veri setidir [18]. Mask R-CNN ağ yapısının halihazırda bu veri seti ile eğitilmiş ağırlıkları bulunmaktadır. Bu ağırlıklar ile sayısal görüntüler üzerinde 80 farklı nesneyi bölütleri ile tespit etmek mümkündür. Gerçekleştirilen bu çalışmada renkli görüntüler için MS-COCO veri seti ile önceden eğitilmiş ağırlık değerleri kullanılmıştır.



Şekil 2. Mask R-CNN yapısı [17]

Tablo 1. Literatürde yer alan ve yaygın olarak kullanılan örnek bölütlemesi yöntemleri.

Yöntem	Öne Çıkan Özellikleri
DeepMask (2015)[12]	Aynı ağ yapısı içerisinde özellik çıkarımından hemen sonra maske ve sınıflandırma işlevleri için dallanan bir yöntemin önerildiği bu çalışma aynı ekip tarafından geliştirilen Mask RCNN'in öncülü olarak görülebilir.
Mask RCNN (2017) [13]	Yüksek başarımlı, esnek ve basit bir örnek bölütlemesi yöntemidir. Evrimsel işlemler sonucu elde edilen ilgilenecek bölgeler (region of interest-ROI) için bir yandan maskeler oluştururken diğer yandan nesne tespitine dair sınıflandırmalar yapar. Gerçek zamanlı uygulamalar için yetersiz kalsa da yüksek başarımlı nedeniyle bir çok çalışmada tercih edilmektedir.
PA-Net (2018) [14]	Mask RCNN ile aynı altyapıyı kullanan bu çalışmada önerilen uyarlamalı özellik ortaklaması (adaptive feature pooling) ile özellik çıkarımı işlemleri sonrası belirlenen ilgilenecek bölgelerin doğruluğu artırılmıştır. Yapılan sınamalarda Mask RCNN'e göre daha başarılı bir yöntem ortaya konmasına karşın daha yavaş kalmıştır.
RetinaMask (2019) [15]	RetinaNet ağı üzerine geliştirilmiştir bir yöntemdir. RetinaNet üzerine tespit edilen nesnelere bölütleme yapan bir ağ yapısı eklenmesiyle oluşturulmuştur. Başarımlı değerleri MaskRCNN'e çok yakın olan bu yöntem hız açısından geride kalmaktadır.
YOLOACT (2019) [16]	Gerçek zamanlı bir örnek bölütlemesi sunulan bu çalışmada başarımlı ispatlanan RetinaMask yöntemi temel alınmıştır. Hız açısından diğer yöntemleri geride bırakarak gerçek zamanlı sistemlere uygulanabileceği sunulan çalışmanın başarımlı temel aldığı RetinaMask'ın da altına düşerek MaskRCNN'den uzaklaşmıştır.

Tablo 2. Örnek bölütlemesinde yaygın olarak faydalanılan veri setleri.


Veri seti Adı	Öne Çıkan Özellikler
PASCAL VOC[19]	20 farklı sınıfta nesnelere içeren bu veri setinde, her bir sınıf için fazla miktarda veri bulunmaktadır. 27.450 adet işaretli veriyi içeren 11.530 görsele sahip iken bölütleme işlemi için 6.929 işaretlemeye bulunmaktadır. Tüm verilerin bölütlemeye hazır olmadığı bu veri setinde bölütleme işaretlemeleri için çalışmalar devam etmektedir.
Mapillary Vistas Dataset[20]	Otonom araba çalışmalarında kullanılmak üzere ortaya çıkarılan ve büyük araç üreticileri tarafından geliştirilmeye devam edilen bir veri setidir. Dünyanın farklı bölgelerinden elde edilmiş cadde görüntülerinden oluşan 25000 görsel içeren bu veri setinde 37 sınıf için bölütleme işaretlemeleri bulunmaktadır.
Cityscapes Dataset[21]	Cadde görüntülerinden oluşan ve otonom araç çalışmalarında kullanılan bu veri setinde 30 farklı sınıfın bölütleme bilgilerini içeren 5000 adet görsel bulunmaktadır. Mapillary Vistas Dataset kadar kapsamlı olmasa da daha basit çalışmalar için kullanılabilir.
MS COCO[18]	Gerek nesne tanıma gerek de bölütleme çalışmalarında kullanılan en kapsamlı veri setlerindedir. Bu veri setinde 330000 bin görsel bulunurken 80 farklı sınıf için toplamda 886000 bölütleme bilgisi bulunmaktadır.

2. Materyal ve Metot

Bu çalışma ile Ms-COCO veri seti ile eğitilmiş Mask R-CNN ağ yapısından faydalanılarak renkli görüntülerde tespit edilen nesnenin renk bilgisini ağ yapısına ve ağırlıklarına müdahale etmeden tespit edilmesi amaçlanmaktadır. Ms-COCO veri seti ile eğitilmiş Mask R-CNN ağ yapısı doğal formu ile aynı renkteki nesnelere aynı etiket ile tespit etmektedir. Ancak bazı uygulamalar aynı nesnelere farklı renk özelliklerinin tespitine ve ayırımına da ihtiyaç duymaktadır. Örneğin trafikte seyir halinde olan bir araç içinden alınan gerçek zamanlı sayısal görüntüler üzerinden, aracın çevresinde yer alan diğer tüm araçları tespit etmek ile sadece bir renkte (örneğin kırmızı) araçları tespit ederek ayrı biçimde belirtmek farklı işlemlerdir. Bu nedenle çalışma kapsamında Şekil 3 ile gösterilen akış diyagramındaki işlem adımlarının sırasıyla gerçekleştirilmesine dayanan bir renk tespit yaklaşımı ortaya konulmuştur.

Şekil 3'de yer alan akış diyagramının ilk adımı görüldüğü üzere kaynak üzerinden sayısal görüntünün alınmasıdır. Bu kaynak bir gerçek zamanlı optik kamera algılayıcısı olabileceği gibi daha önceden bir algılayıcı ile edinilmiş depolanan bir video ya da görüntü verisi de olabilir. Uygulamaya göre bu durum değişiklik gösterebilir. Kaynak tipi, bu çalışma kapsamında geliştirilen yöntemden bağımsız olabilir. Bu nedenle ortaya konulan yöntem kaynak tipinden çok formatı ile ilgilenmektedir. Farklı renk

derinliklerinde ham ya da formatlı veri giriş görüntüsü olarak kullanılabilir.

**Şekil 3.** Renk tespiti yaklaşımı

Kaynaktan alınan sayısal renkli görüntü derin öğrenme yaklaşımı dahilinde MS COCO veri seti ile eğitilmiş Mask R-CNN sinir ağı içinde işlenerek görüntü üzerinde yer alan bağımsız nesnelere tespit edilir. Bu aşamada örnek bölütlemesi işlemi ile nesnelere birbirlerinden kesin sınırlar ile sayısal görüntü üzerinde ayrılırlar.

Tespit edilen nesneyi içeren en küçük çerçevenin (minimum bounding box) merkez noktasının renk değeri nesnenin rengi olarak değerlendirilebilir. Bu basit yöntem yaklaşık sonuçlar üretse de merkez noktadaki verinin nesnenin tamamını yansıtmayabileceği düşünülebilir. Çerçeve içerisindeki renk verilerinin ortalama değeri de nesne rengi olarak düşünülebilir. Ancak çerçeve içerisinde kalan alanda nesneye ait olmayan bölgelerin olması da kaçınılmazdır. Nesnenin şekil ve konumuna göre bu alanların nesneden daha fazla piksel alanını kaplayacağı durumlar oluşacağı da düşünüldüğünde yeni bir yaklaşım ile bu sorunun çözülmesi gerekliliği ortaya çıkmaktadır. Kullanılacak olan yaklaşımın görüntüler üzerinde sadece tespit değil nesnelere ayırma yapması da gereklidir.

Bölütme işlemi sonrasında elde edilen bölgedeki renk değerleri ağırlığının belirlenmesi gerekmektedir. Bu amaçla kümeleme yaklaşımlarından yararlanılmıştır. Her nesne için kendine has renk değerleri üretileceği için kullanılacak yöntemin denetimsiz bir öğrenme yöntemi olması gerekmektedir. Herhangi bir etiketlemeye gerek duymadan kümelenebilir veriler sayesinde nesnenin ağırlıklı renk tonu bilgisine erişilebilmiştir. Kümeleme sonrasında yapılacak sınıflandırma ile rengin ait olduğu bölge belirlenmiş ve son olarak tespit sonucu çıktı olarak üretilmiştir.

K-Means birden fazla özelliğe göre kümeleme yapabilme yeteneğine sahip bir algoritmadır. Algoritma çalıştırılırken başlangıçta belirlenen K değeri kadar rastgele küme merkezi seçilir. Veriler bu küme merkezlerine uzaklıkları hesaplanarak kümelere dahil edilir. Her işlem sonrasında yeni merkez hesaplanır ve kümeleme kararlı sonuca erişinceye kadar bu işlemler tekrar edilir [22]. Çalışmada K değeri 5 olarak belirlenerek nesnenin bölüt sınırları içerisindeki renk tonlamaları beş ana kümeye ayrılmıştır.

Renk tespiti için kümeleme sonrasında elde edilen en yoğun kümeye sahip değerlerin sınıflandırılması gerekmektedir. Bu aşamada makine öğrenmesinde kullanılan çeşitli algoritmalar arasından seçilen k En Yakın Komşu (KNN) algoritması kullanılmıştır. Bu algoritma da herhangi bir eğitime ihtiyaç duymadan çalışabilen tembel bir algoritmadır. Belirlenen K değeri kadar elemanın uzaklığı hesaplanarak sınıflandırma yapılır. Uzaklık hesaplaması için temelde Öklid yöntemi kullanılan bu algoritmada Hamming, Manhattan ve Minkowski yöntemleri de kullanılabilir[23].

Sayısal ortamda görüntülerin temsili için çeşitli renk uzayları kullanılmaktadır. Yaygın olarak kullanılan Red Green Blue (RGB, Kırmızı Yeşil Mavi) renk uzayı

Öklid benzeri mesafe hesaplamalarına uygun olmadığı için kümeleme ve sınıflandırma işlemi için Hue Saturation Value (HSV, Renk Doymuluk Değer) renk uzayı kullanılmaktadır [24]. Her iki renk uzayındaki piksel yoğunluk değerleri Denklem (1), (2) ve (3) yardımı ile birbirine dönüştürülebilir. Çalışmada kullanılan kümeleme ve sınıflandırma algoritmalarının verimli çalışabilmesi için piksel renk yoğunlukları HSV renk uzayına dönüştürülerek işlenmiştir.

$$V = \text{Enbüyük}(R, G, B) \quad (1)$$

$$S = V - \frac{\text{Enküçük}(R, G, B)}{V} \quad (2)$$

$$H = \begin{cases} \frac{G - B}{6xS} & \text{eğer } V = R, \\ \frac{1}{3} + \frac{B - R}{6xS} & \text{eğer } V = G, \\ \frac{2}{3} + \frac{R - G}{S} & \text{eğer } V = B. \end{cases} \quad (3)$$

Renk uzayının belirlenmesinden sonra çalışmada kullanılacak renk adları için renk uzayı değerlerinin tanımlanması gerekmektedir. Centro yaptığı çalışmada renkleri adlandırma yöntemi olan ISCC-NBS sistemi için RGB değerleri ve renk adları tanımlamalarını yapmıştır. Bu tanımlamalar 3 seviyeye ayrılmış ve seviyelerde sırasıyla 13, 29 ve 267 renk tanımlı gerçekleştirilmiştir. Tanımlamalar yapılırken aşamalı bir renk adlandırılması yapıldığı gözlenmektedir [25]. Centro'nun belirlediği 267 adet renk tanımına ait RGB değerleri HSV değerlerine çevrilerek kümeleme ve sınıflandırma algoritmaları ile kullanılabilir biçime getirilmiştir.

3. Bulgular

Materyal ve metod bölümünde akış şeması verilen ve açıklanan yaklaşımın sınanması için gerçek dünyada kullanılabilir bir amaca hizmet etmesi düşünülmüştür. Renk belirleme işleminin kullanılabilir alanların başında araç gözetleme sistemleri gelmektedir. Literatürde bulunan araç veri setleri incelendiğinde birçok veri setinin renk bilgisinden yoksun olduğu gözlemlenmiştir. Kendi alanındaki ender çalışmalardan olan VRAI araç tanımlama veri seti renk bilgisi de içerdiğinden çalışmanın sınanması için kullanılmıştır [26]. VRAI veri setinde test için ayrılmış veriler içinden arabalar ayrılmış ve görüntüler üzerinde hiçbir iyileştirme yapılmadan sınamalar gerçekleştirilmiştir. Sınama yapılan verilerin renk dağılımları, renklere göre ve toplam başarımları Tablo 3'te gösterilmiştir. 11.241 adet görsel üstünde yapılan sınama sonucu 7.900 görselin renk bilgisi doğru tespit edilerek %70,28 oranında bir başarı sağlanmıştır.

Tablo 3. Sınama sonuçları

Renk	Toplam	Doğru Tespit	Yanlış Tespit	Başarım
Beyaz	4513	3136	1377	69,49
Siyah	2988	2579	409	86,31
Gri	1521	730	791	47,99
Kırmızı	570	341	229	59,82
Yeşil	769	563	206	73,21
Mavi	516	473	43	91,67
Sarı	102	64	38	62,75
Kahverengi	262	14	248	5,34
Toplam	11241	7900	3341	70,28

Tablo 4. Renk bazında doğruluk tablosu


	B	S	G	K	Y	M	S	Ka
B	3136	77	593	1	244	225	227	10
S	4	2579	292	3	2	107	0	1
G	426	87	730	2	47	190	11	28
K	0	69	39	341	4	16	7	94
Y	16	25	65	0	563	95	3	2
M	1	1	0	12	28	473	0	1
S	0	1	6	20	0	6	64	5
Ka	0	52	148	2	10	36	0	14

Şekil 4'te veri setindeki örnek bir görsel üzerinde yaklaşımın sonuçlar görülmektedir. Şekil 4(a)'da tespit edilen nesneyi içeren çerçeve ve nesnenin bölütü görülmektedir. Şekil 4(b)'de nesneyi içeren çerçevenin küme merkezlerinin piksel değerleri ile küme üyelerinin yüzdelik dağılımı görülürken Şekil 4(c)'de kümelemenin görsel olarak renklendirilmiş hali görülebilir. Şekil 4(d)'de örnek bölütlemesi sonucu elde edilen bölgedeki küme merkezlerinin piksel değerleri ile küme üyelerinin yüzdelik dağılımı, Şekil 4(e)'de ise kümelemenin renklendirilmiş hali bulunmaktadır. Bölütleme alanında yapılan kümelemenin daha başarılı sonuç üreteceği Şekil 4(b), Şekil 4(c) ile Şekil 4(d), Şekil 4(e) karşılaştırılarak görülmektedir.

4. Tartışma ve Sonuç

Sunulan çalışma ile örnek bölütlemesine dayalı bir renk ve nesne tespit yaklaşımı sunulmuştur. Yaklaşımın başarısı literatürde var olan bir araç tanımlama veri seti üzerinde sınanmıştır. Veri setindeki görüntüler ve bölütleme işlemini gerçekleştirilen ağ yapısı üzerinde herhangi bir iyileştirme yapılmadan yüzde 70,28 oranında doğruluğa ulaşılmıştır. Yaklaşım bölütleme için kullanılan ağ yapısının eğitim seti ve özelliklerinden bağımsız olarak işleyen bir yapıda olmasından dolayı literatürde var olan farklı yaklaşımlara kolaylıkla uygulanabilir. Ayrıca literatürde renk tanımı bulunan farklı nesnelere içeren veri setleri üzerinde de sınanabilir. Bunun yanı sıra güvenlik kamerası görüntülerinden tespit edilen araçların renginin belirlenmesi, bir üretim bandında sınıflandırılan

nesnelerin renk kontrolü yapılması gibi herhangi bir alanda gerçekleştirilecek özelleştirilmiş çalışmalar için de kolaylıkla uygulanabilir. Şekil 5'te Bahnsen ve arkadaşları tarafından hazırlanan bir trafik gözetleme veri seti [27] üzerinde yaklaşım ile elde edilen sonuçlar görülmektedir. Şekil incelendiğinde trafik akışında tespit edilebilen araçların üzerine belirleyici renk tanımlamaları yapıldığı görülmektedir. Çalışma yaklaşımının uyarlanması ile farklı algılayıcılardan alınan veriler üzerinde yapılacak tespitler sonucu algılayıcı özelliğine göre sınıflandırmalar gerçekleştirilebilir. Örneğin derinlik verilerden oluşan bir görselde tespit edilecek nesnenin uzaklık yakınlık durumu bulunabilirken sıcaklık verilerinden oluşan görsellerde tespit edilen nesnenin sıcaklık soğukluk durumu sınıflandırılabilir.



(a)

[12.69471187	28.692898	121.37993582]	5.99%
[155.74530215	85.35401739	81.02108963]	18.53%
[171.58077035	184.23596402	131.78637748]	23.03%
[170.78417318	126.7078704	196.91169092]	23.32%
[136.15004167	22.20582234	123.55524902]	29.13%



(c)

[13.60772394	32.82728411	124.53835151]	6.53%
[170.27873027	128.83033441	94.63079273]	13.77%
[135.11467673	39.2184521	110.04936291]	24.68%
[171.63577148	191.21368797	142.15085719]	25.81%
[170.75512406	126.48927244	199.53969395]	29.21%

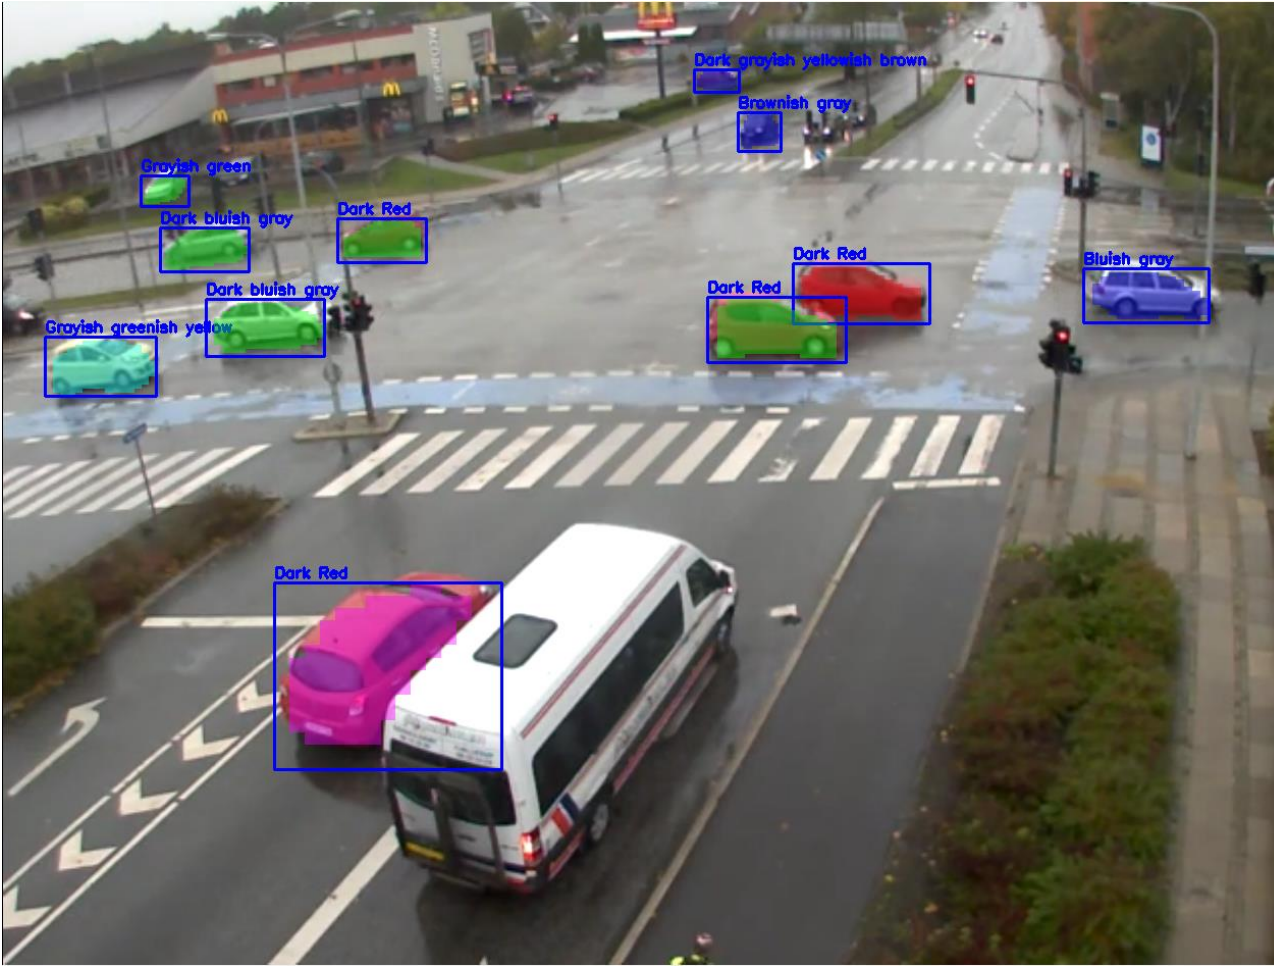


(e)

Şekil 4. Örnek nesnenin renk tonu kümelenmeleri, (a) tespit edilen nesne, (b) çerçeve içerisindeki alanın renk tonu kümelenmesi, (c) çerçeve içerisindeki alanın renk tonu kümelenmesinin görselleştirilmesi, (d) bölütleme alanının renk tonu kümelenmesi, (e) bölütleme alanının renk tonu kümelenmesinin görselleştirilmesi

Etik Beyanı/Declaration of Ethical Code

Bu çalışmada, "Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi" kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin "Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler" başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.



Şekil 5. Uygulama örneği, trafik gözetleme verisinde [27] elde edilen sonuçlar

Kaynakça

- [1] Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z., & Qu, R. (2019). A Survey of Deep Learning-Based Object Detection. *IEEE Access*, 7, 128837-128868.
- [2] Lin, T., Goyal, P., Girshick, R., He, K., & Dollar, P. (2017). Focal Loss for Dense Object Detection. *2017 IEEE International Conference On Computer Vision (ICCV)*.
- [3] Chao, P., Kao, C., Ruan, Y., Huang, C., & Lin, Y. (2019). HardNet: A Low Memory Traffic Network. *2019 IEEE/CVF International Conference On Computer Vision (ICCV)*.
- [4] Tan, M., Pang, R., & Le, Q. (2020). EfficientDet: Scalable and Efficient Object Detection. *2020 IEEE/CVF Conference On Computer Vision And Pattern Recognition (CVPR)*.
- [5] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference On Computer Vision And Pattern Recognition (CVPR)*.
- [6] Guo, Y., Liu, Y., Georgiou, T., & Lew, M. (2017). A review of semantic segmentation using deep neural networks. *International Journal Of Multimedia Information Retrieval*, 7(2), 87-93.
- [7] Momin, B., & Mujawar, T. (2015). Vehicle detection and attribute based search of vehicles in video surveillance system. *2015 International Conference On Circuits, Power And Computing Technologies [ICCPCT-2015]*.
- [8] Chu, W., Liu, Y., Shen, C., Cai, D., & Hua, X. (2018). Multi-Task Vehicle Detection With Region-of-Interest Voting. *IEEE Transactions On Image Processing*, 27(1), 432-441.
- [9] Artan, Y., Alkan, B., Balci, B., & Elihos, A. (2019). Deep Learning Based Vehicle Make, Model and Color Recognition Using License Plate Recognition Camera Images. *2019 27Th Signal Processing And Communications Applications Conference (SIU)*.
- [10] Bai, M., & Urtasun, R. (2017). Deep Watershed Transform for Instance Segmentation. *2017 IEEE Conference On Computer Vision And Pattern Recognition (CVPR)*.
- [11] Bahnsen, C., & Moeslund, T. (2019). Rain Removal in Traffic Surveillance: Does it Matter?. *IEEE Transactions On Intelligent Transportation Systems*, 20(8), 2802-2819.

- [12] Pinheiro, P., Lin, T., Collobert, R., & Dollár, P. (2016). Learning to Refine Object Segments. *Computer Vision – ECCV 2016*, 75-91.
- [13] He, K., Gkioxari, G., Dollar, P., & Girshick, R. (2017). Mask R-CNN. *2017 IEEE International Conference On Computer Vision (ICCV)*.
- [14] Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path Aggregation Network for Instance Segmentation. *2018 IEEE/CVF Conference On Computer Vision And Pattern Recognition*.
- [15] Fu, C. Y., Shvets, M., & Berg, A. C. (2019). RetinaMask: Learning to predict masks improves state-of-the-art single-shot detection for free. *arXiv preprint arXiv:1901.03353*.
- [16] Bolya, D., Zhou, C., Xiao, F., & Lee, Y. (2019). YOLACT: Real-Time Instance Segmentation. *2019 IEEE/CVF International Conference On Computer Vision (ICCV)*.
- [17] Bayram F. (2020). Derin öğrenme tabanlı otomatik plaka tanıma. *Politeknik Dergisi*, 23(4), 955-960.
- [18] Lin, T., Maire, M., Belongie, S., Hays, J., Perona, P., & Ramanan, D. et al. (2014). Microsoft COCO: Common Objects in Context. *Computer Vision – ECCV 2014*, 740-755.
- [19] Everingham, M., Eslami, S., Van Gool, L., Williams, C., Winn, J., & Zisserman, A. (2014). The Pascal Visual Object Classes Challenge: A Retrospective. *International Journal Of Computer Vision*, 111(1), 98-136.
- [20] Neuhold, G., Ollmann, T., Buló, S., & Kotschieder, P. (2017). The Mapillary Vistas Dataset for Semantic Understanding of Street Scenes. *2017 IEEE International Conference On Computer Vision (ICCV)*.
- [21] Cordts, M., Omran, M., Ramos, S., Rehfeld, T., Enzweiler, M., & Benenson, R. et al. (2016). The Cityscapes Dataset for Semantic Urban Scene Understanding. *2016 IEEE Conference On Computer Vision And Pattern Recognition (CVPR)*.
- [22] Vassilvitskii, S., & Arthur, D. (2006). k-means++: The advantages of careful seeding. In *Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms* (pp. 1027-1035).
- [23] N. Bhatia and V. Ashev, (2010). Survey of Nearest Neighbor Techniques, *International Journal of Computer Science and Information Security*, 8(2), 1-4.
- [24] Ajmal, A., Hollitt, C., Freen, M., & Al-Sahaf, H. (2018). A Comparison of RGB and HSV Colour Spaces for Visual Attention Models. *2018 International Conference On Image And Vision Computing New Zealand (IVCNZ)*.
- [25] Centore, P. (2016). sRGB Centroids for the ISCC-NBS Colour System, <https://www.munsellcolourscienceforpainters.com/ColourSciencePapers/sRGBCentroidsForTheISCCNBSColourSystem.pdf> (Erişim Tarihi: 10.11.2021).
- [26] Wang, P., Jiao, B., Yang, L., Yang, Y., Zhang, S., Wei, W., & Zhang, Y. (2019). Vehicle Re-Identification in Aerial Imagery: Dataset and Approach. *2019 IEEE/CVF International Conference On Computer Vision (ICCV)*.
- [27] Bahnsen, C., & Moeslund, T. (2019). Rain Removal in Traffic Surveillance: Does it Matter?. *IEEE Transactions On Intelligent Transportation Systems*, 20(8), 2802-2819.