



# Otonom Sistemlerde Veri Çoğaltma Yöntemleri Kullanılarak İyileştirilmiş Gerçek Zamanlı Nesne Tespiti

Fırat Bozkaya<sup>1\*</sup>, Abdullah Yusefi<sup>2</sup>, Şükrücan Tıǧlıođlu<sup>3</sup>, Ahmet Kađan Kaya<sup>4</sup>, Okan Kazancı<sup>5</sup>, Mustafa Yasin Akmaz<sup>6</sup>, Akif Durdu<sup>7</sup>, Cemil Sungur<sup>8</sup>

<sup>1\*</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0002-4310-9490), [ffbozkaya97@gmail.com](mailto:ffbozkaya97@gmail.com)

<sup>2</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0001-7557-8526), [a.yusefi1991@gmail.com](mailto:a.yusefi1991@gmail.com)

<sup>3</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0003-3939-8987), [sukru28980@gmail.com](mailto:sukru28980@gmail.com)

<sup>4</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0002-7845-7292),  
[kayakagan10@gmail.com](mailto:kayakagan10@gmail.com)

<sup>5</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0002-6184-3349), [okankazanci29@gmail.com](mailto:okankazanci29@gmail.com)

<sup>6</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0002-3608-1290),  
[mustafa.akmaz19@gmail.com](mailto:mustafa.akmaz19@gmail.com)

<sup>7</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0002-5611-2322), [adurdu@ktun.edu.tr](mailto:adurdu@ktun.edu.tr)

<sup>8</sup> Konya Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliđi Bölümü, Konya, Türkiye, (ORCID: 0000-0003-2340-6225),  
[csungur@ktun.edu.tr](mailto:csungur@ktun.edu.tr)

(2nd International Conference on Computer, Electrical and Electronic Sciences ICCEES 2021, September 1-3, 2021)

(DOI: 10.31590/ejosat.1006408)

**ATIF/REFERENCE:** Bozkaya, F., Yusefi, A., Tıǧlıođlu, Ş., Kaya, A. K., Kazancı, O., Akmaz, M. Y., Durdu, A. & Sungur, C. (2021). Otonom Sistemlerde Veri Çoğaltma Yöntemleri Kullanılarak İyileştirilmiş Gerçek Zamanlı Nesne Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (30), 83-87.

## Öz

İnsan müdahalesi olmadan çalışan sistemler savunma sanayi başta olmak üzere pek çok alanda gün geçtikçe önemi ve kullanımı artmaktadır. Bu sistemlerde insan faktörü azaltılarak maliyet ve zamandan kazanç sağlansa da görüntü işleyerek çalışan sistemlerde doğruluk oranının yüksek olmaması durumunda yeni problemler ortaya çıkmaktadır. İnsan müdahalesi olmadan çalışan kara araçları için levha tespitindeki hatalı tespit problemleri, hava araçlarında ise iniş noktasının doğru tespit edilememesi gibi problemlerdir. Bu çalışmada hava aracından çekilmiş görüntüler kullanılmıştır. Bu görüntüler üzerinde çeşitli veri çoğaltma yöntemleri kullanılarak nesne tespit oranının artırılmasıyla tespit problemlerinin giderilmesi üzerine çalışılmıştır. Veri çoğaltma yöntemlerinde Gaussian, karlanma, gölgelendirme, yüksek gama, Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE), artırılmış parlaklık, azaltılmış parlaklık yöntemleri uygulanarak veri çoğaltma işlemi yapılmış olup nesne tespitinde kullanılacak olan model eğitimi YOLOv4 algoritmasıyla gerçekleştirilmiştir. Sonuçlar gözlemlendiğinde 8000 tekrar sonrasında başarı oranının %94'e kadar çıktığı ve kayıp (loss) değerinin 0.42 sonucunu verdiği gözlemlenmiştir. Eğitilen model simülasyon ortamına gerek duyulmadan gerçek araçta denenmiştir.

**Anahtar Kelimeler:** Veri Çoğaltma, Nesne Tanıma, YOLOv4, Görüntü İşleme, İnsansız Hava Araçları

## Improved Real Time Object Detection In Autonomous Systems Using Data Augmentation Methods

### Abstract

The importance and application of systems that work without human involvement are growing in many industries, particularly in the defense industry. Although minimizing the human role in these systems saves money and time, it also introduces new challenges if the accuracy rate in image processing systems isn't high enough. Erroneous traffic sign detection for land vehicles running without human assistance, as well as a failure to correctly estimate the landing site in aircraft. In this study, images from the plane were collected and used to enhance object detection in autonomous systems. On these photos, several data augmentation approaches have been used to try to alleviate the detection challenges by increasing the object detection rate. Data reproduction methods included Gaussian, snow, shading, high gamma, Contrast Limited Adaptive Histogram Equalization (CLAHE), raised luminance, and lowered luminance methods, as well as data augmentation. The YOLOv4 algorithm was utilized to train the model for object detection. When the findings were examined, it was discovered that after 8000 repetitions, the success rate had increased to 94 percent, and the loss value had decreased to 0.42. In addition to the simulation environment, the trained model was also evaluated in a real ground vehicle.

**Keywords:** Data Augmentation, Object Detection, YOLOv4, Image Processing, Unmanned Aerial Vehicles

\* Sorumlu Yazar: [ffbozkaya97@gmail.com](mailto:ffbozkaya97@gmail.com)

## 1. Giriş

Günümüzde, insan müdahalesi olmadan çalışan (otonom) sistemler sıkça kullanılmaktadır. Çeşitli amaçlarla kullanılan otonom sistemler, geniş bir alana hitap etmektedir. Otonom sistemlerin temel amacı insan faktörünü azaltmaktır. İnsan faktörü ön planda tutulan sistemlerde maliyet ve zaman açısından dezavantaj olmaktadır. İnsan faktörünün azaltılmasıyla beraber zaman ve maliyetten kazanç sağlanmasının yanı sıra hatalarda minimum düzeye indirilecektir. Otonom sistemlerin çoğu, bir ya da birden fazla kamera yardımıyla alınan görüntünün işlenmesiyle çalışmaktadır. Sistemin doğruluğu ise gelen görüntünün doğru bir şekilde işlenip işlenmediğine bağlıdır. Görüntünün işlenmesi kısmında doğruluk oranının yüksek olmaması durumunda yeni problemler ortaya çıkmaktadır. Bu problemlerden biri, otonom olarak hareket eden bir kara aracının yol kenarındaki levhaları yanlış bir şekilde tespit etmesidir. Örneğin, sola dönülmez levhasının yanlış şekilde tespit edildiği bir durumda otonom çalışan kara aracı sola dönebilir ve kaza yapma riski oluşturabilir. Hava araçlarında karşılaşılabilecek problemler arasında ise iniş noktasının doğru tespit edilememesi ve yanlış bir noktanın iniş noktası olarak tespit edilmesi halinde istenmeyen durumlara sebebiyet verebilir. Bu yanlış tespit problemleri nesne tespitindeki başarı oranı yükseltilerek önlenebilir. Bunun için hava aracından çekilmiş görüntüler kullanılmıştır. Bu çalışmada nesne tespitindeki başarı oranını yükseltebilmek için görüntüler üzerinde çeşitli veri çoğaltma yöntemlerinden faydalanılmıştır.

Veri çoğaltma yöntemlerinde Gaussian, karlanma, gölgelendirme, yüksek gama, Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) [1], artırılmış parlaklık, azaltılmış parlaklık yöntemleri kullanılmaktadır. Yapılan bu çalışmada ağırlıklı olarak CLAHE yöntemi üzerinde durulmuştur. Ayrıca yapılan bu veri çoğaltma işlemlerinden sonra elde edilen veri setiyle beraber nesne tanımda kullanılacak olan model eğitimi, YOLOv4 [2] algoritmasıyla gerçekleştirilmiştir.

Bildirinin geri kalan kısmının ikinci bölümünde çalışmayı yaparken kullanılan görüntü kirlenme algoritmaları, YOLOv4 algoritması yöntemlerinin anlatılmasının yanı sıra kullanılan materyaller ve literatür araştırması yapılmıştır. Üçüncü bölümde model eğitimi ve sonrasında ortaya çıkan bulgulara yer verilmiştir. Dördüncü bölümde çalışmayla ilgili gözlem ve sonuçlara yer verilmiştir. Beşinci bölümde ise çalışmada yararlanılan kaynaklar yer almaktadır.

## 2. Materyal ve Metot

### 2.1. Görüntü Kirlenme Algoritmaları

Görüntü kirlenme, veri setindeki çeşitliliği arttırmak amacıyla kullanılan veri çoğaltma işlemleridir. Karşılaşılabilecek farklı görüntü kirlenmelerinde (gölgelendirme, artırılmış parlaklık, azaltılmış parlaklık vb.) modelin nesne tespitinde kullanılan veri seti çeşitliliğinin artmasıyla modelin tespit yeteneği doğru oranda artacaktır. Kullanılan görüntü kirlenme yöntemleri Gaussian gürültüsü, karlandırma, gölgelendirme, gamma artırma, güneş parlaklığını artırma ve ışık oranını azaltma olarak kullanılmıştır. Bunlara ek olarak CLAHE algoritması da görüntü kirlenme algoritmalarıyla beraber model eğitimi için kullanılmıştır.

CLAHE algoritması görsellerdeki yerel kontrastı geliştiren bir algoritmadır. Böylelikle, veri setindeki renk farklılıkları azaltılabilmektedir. Bunlarla birlikte histogram eşitleme (HE) teknikleri de kullanılmaktadır. Histogram eşitleme tekniği,

görüntünün kontrastını arttırmak için kullanılan yaygın bir yöntemdir. Uyarlanabilir Histogram Eşitleme (AHE) ise görüntünün bazı bölgelerine karşılık gelen birkaç histogramı hesaplayarak yerel kontrastı geliştirip yerel bilgi kaybını azaltmaktadır. CLAHE, HE ve AHE yöntemlerini baz alarak kontrastın limitlenmesini sağlar [1]. Böylece önceden verilen değerde histogramı kırpmasını sağlayarak büyümeyi önler. CLAHE algoritması, veriler içerisinde daha kaliteli görüntüler elde edilmesini sağlamaktadır. Nesne tespit modeli için veri seti oluştururken veri çeşitliliğini çoğaltmak amacıyla CLAHE algoritması kullanılarak daha kaliteli görüntü oluşturulmuştur. Orijinal görüntü ve CLAHE algoritması uygulanmış görüntü Şekil 1.a ve Şekil 1.b'de verilmiştir.



Şekil 1.a: Orijinal Görüntü



Şekil 1.b: CLAHE Uygulanmış Görüntü

Gaussian bulanıklaştırması ile görüntü üzerindeki gürültülerin azaltılması amaçlanmaktadır. Gürültünün çok olması durumunda tespit oranları düşmekte olup yanlış tespit ihtimali artmaktadır. Gaussian bulanıklaştırması kullanıldığında tespit oranları artmaktadır. Gaussian bulanıklaştırmasını kullanmak için iki boyutta Gauss fonksiyonu kullanılmaktadır. Bu fonksiyon aşağıda verilmiştir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (1)$$

Bu fonksiyonda kullanılan  $x$  ve  $y$  parametreleri, merkez pikselden (0,0) delta'yı belirtir. Örneğin, çekirdek için seçilen yarı çap 3 ise  $x$  ve  $y$  -3 ile 3 (dahil) arasında değişim göstermektedir. Bu fonksiyonda diğer bir parametre olan  $\sigma$  ise standart sapmadır. Merkez pikselin, komşu piksellerinin hesaplama sonucunu ne kadar önemli ölçüde etkilediğini belirtir [3].

Karlandırma (snow) tekniği HLS [5] renk uzayındaki görüntünün açıklık artırma yöntemini kullanarak, çoğunlukla yollar, ağaçlar, dağlar ve diğer peyzaj özellikleri olan görüntünün en karanlık kısımlarını beyazlatır. Böylelikle görselde bulunan alanlarda karlanma varmış gibi bir görüntü elde edilir.

Gölgelendirme tekniği görüntü içerisindeki belirli alanlara rastgele olarak gölgeler ekler. Böylelikle tepelerde veya ormanlık alanda rastgele değişen parlaklık, doğru şekilde eğitilmemişse bu sorunun önüne geçilebilir.

Gamma değeri bir görüntünün kontrast ölçümüdür. Yüksek gamma değerinde kontrast değeri yüksekken düşük gamma değerinde ise kontrast değeri düşük olur. Gamma değerinin yükseltilmesi sayesinde kontrast artacak olup renkler arasındaki karşıtlık artacak; ayrıca görüntüdeki çizgiler, şeritler daha belirgin olacaktır.

Görüntünün parlaklık değerinin artırılmasıyla resim üzerinde bulunan nesnelerin renkleri daha ön plana çıkacaktır. Aynı şekilde görüntünün parlaklık değeri azaltılırsa resim üzerinde bulunan nesneler daha koyu bir şekilde gözükülecektir. Bu sayede veri sayısı

artarak farklı ışık miktarlarında tespit oranının arttığı gözlemlenmiştir.


Anlatılan görüntü kirlenme yöntemleri Şekil 2'de ilgili resimlerde gösterilmiştir.



Şekil 2: Kirlenme Algoritmalarının Uygulanması

## 2.2. Konvolüsyonel Sinir Ağı

Konvolüsyonel sinir ağları (CNN) [6], derin öğrenmenin bir alt dalıdır ve genellikle görsel bilginin analiz edilmesinde kullanılmaktadır. Yaygın kullanım alanları resim ve video tanıma, öneri sistemleri, resim sınıflandırma, tıbbi görüntü analizi ve doğal dil işleme olarak sıralanabilmektedir. İleri yönlü bir sinir ağı olan konvolüsyonel sinir ağı algoritması, hayvanların görme merkezinden esinlenilerek ortaya atılmıştır. Buradaki matematiksel konvolüsyon işlemi, bir nöronun kendi uyarı alanından uyarılara verdiği cevap olarak düşünülebilir. CNN, bir veya daha fazla konvolüsyonel katman, alt örnekleme (subsampling) katmanı ve bunun ardından standart çok katmanlı bir sinir ağı gibi bir veya daha fazla bağlı katmandan oluşmaktadır [4]. Bu bağlı katmanların birbiriyle ilişkisi Şekil 3'te gösterilmiştir.




Şekil 3: Konvolüsyonel Sinir Ağı Katmanları

## 2.3. YOLOv4 Algoritması

YOLO, konvolüsyonel sinir ağları (CNN) üzerine kurulmuş olup, videolardan ve görüntülerden nesne tespiti yapabilen bir derin öğrenme algoritmasıdır [2]. Bu algoritmada görüntüye bir sinir ağı uygulanır. Bu sinir ağı görüntüyü bölgelere ayırmaktadır ve her bölge için olasılıkları ve sınırlayıcı kutuları tahmin etmektedir. Bu sınırlayıcı kutular her bir bölgede nesne bulunma olasılığını hesaplar. Ayrıca her sınırlayıcı kutu için bir güven

skoru da hesaplanmaktadır. Bu skor sayesinde o nesnenin yüzde kaç ihtimalle tahmin edilen nesne olduğunu ortaya çıkartmaktadır. Örneğin bulunan bir insan için güven skoru 0,2 ise o nesnenin insan olma olasılığı oldukça düşüktür. YOLO, yaptığı tahminin güvenilmez olduğunu güven skoru aracılığıyla belirtmektedir. Sınırlayıcı kutularda bulunan nesnelere Maksimum Olmayanı Baskılama (Non-Maximum Suppression) yöntemi [7] uygulanmaktadır. Bu işlem güven skorlarını karşılaştırarak güven skoru düşük olan nesnelere değerdendirilmeden çıkartır ve aynı bölgede güven skoru daha yüksek olan bir sınırlayıcı kutu olup olmadığını kontrol eder. Daha yüksek bir sınırlayıcı kutu olması durumunda en yüksek güven skoru olan işaretleyerek diğer sınırlayıcı kutuları görüntüden çıkartmaktadır. Bu sınırlayıcı kutular aracılığıyla nesne tespiti örneği Şekil 4'te verilmiştir.



Şekil 4: Sınırlayıcı Kutular Aracılığıyla Nesne Tespiti


YOLOv4 modeli, nesne tanıma algoritmasının dördüncü sürümüdür. Bu sürüm önceki sürümlerde olduğu gibi hem bir kez konvolüsyonel sinir ağı modelinden geçmekte hem de MS-COCO veri kümesinden faydalanmaktadır. Bu sayede saniyede işlenen kare hızında ciddi bir artış olmakla beraber gerçek zamanlı nesne tespiti yapılmasına olanak sağlamaktadır.

## 3. Araştırma Sonuçları ve Tartışma

### 3.1. Bulgular

İnternet üzerinde bulunan hava aracının kaydettiği görüntüler kullanılarak bu görüntüleri Kısım 2.A'da bahsedildiği gibi çeşitlendirilerek YOLOv4 modelinde eğitim gerçekleştirilmiştir. Bu eğitimlerde RTX 2060 ekran kartı kullanılmış olup YOLOv4 modelinde eğitim 12 saat sürmüştür. Eğitim sonunda ağırlıklar incelendiğinde, düşük iterasyon sayısında oluşan ağırlıkların nesne tespitinde birden fazla sınırlayıcı kutu çizdiği görülmektedir. Nesne tespit oranının artması için aşağıda verilen matematiksel işlem uygulanmıştır.


Bu alandaki sınıf sayısı tespit edilecek farklı nesne sayısıdır. Görüntü kirlenme işlemleri uygulanmış ve uygulanmamış model üzerindeki örnek görüntüler Şekil 5.a-d'de verilmiştir. Şekil 5.a-d'de yer alan sınıflar Uçan Araba Park (UAP), insan, Uçan Ambulans İniş (UAI) alanıdır. Eğitilen modeller simülasyon ortamına gerek duyulmadan gerçek araçta denenmiştir.




Şekil 5.a: Görüntü Kirlenme Uygulanmamış Model



Şekil 5.b: Görüntü Kirlenme Uygulanmış Model




Şekil 5.c: Karlanmış Görsel Üzerinde Nesne Tespiti



Şekil 5.d: Gama Uygulanmış Görsel Üzerinde Nesne Tespiti

Kullanılan YOLOv4 modelinin 8000 tekrar sonrasında başarı değerinin %94'e kadar çıktığı ve loss değerinin 0.42 sonuç verdiği gözlemlenmiştir. Bu eğitim bilgileri Şekil 6'da gösterilmiştir.



Şekil 6: YOLOv4 Eğitim Sonuçları

Mavi eğri, eğitim kaybı veya eğitim veri kümesindeki hata oranıdır. Kırmızı çizgi, modelin daha önce hiç görülmemiş bir veri kümesinde veya doğrulama kümesinde iyi bir şekilde tespit edip edemediğini kontrol eden ortalama kesinlik oranıdır.

## 4. Sonuç

Test amaçlı eğitilen modeller, gerçek araç üzerinde test edildiğinde düşük sayıda veriyle hazırlanan modelin doğruluk oranının düşük olduğu ve görüntü kirlenme algoritmaları uygulanarak veri çoğaltma yöntemleriyle hazırlanan modelin doğruluk oranının daha yüksek olduğu gözlemlenmiştir. Bu sayede insan müdahalesi olmadan nesne tespiti yaparak çalışan sistemlerin kazaya sebebiyet vermeden sorunsuz bir şekilde çalışmalarına olanak sağladığı saptanmıştır.

## 5. Teşekkür

Yazarlar ayrıca Konya Teknik Üniversitesi RAC-LAB Araştırma Laboratuvarı'na (<http://www.rac-lab.com>) teşekkür eder.

## Kaynakça

- [1] (2021) Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE), [Online]. Available: <https://github.com/YuAo/Accelerated-CLAHE>
- [2] FBochkovskiy, Alexey, et al. "YOLOv4: Optimal Speed and Accuracy of Object Detection." ArXiv:2004.10934 [Cs, Eess], Apr. 2020. arXiv.org,
- [3] (2021) Image Filters: Gaussian Blur [Online]. Available: <https://aryamansharda.medium.com/image-filters-gaussian-blur-eb36db6781b1>
- [4] ŞEKER, Abdulkadir, et al. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. 15 Nov. 2017. dergipark.org.tr,
- [5] Meeus, Wim, et al. "An overview of today's high-level synthesis tools." Design Automation for Embedded Systems 16.3 (2012): 31-51.
- [6] Yamashita, Rikiya, et al. "Convolutional neural networks: an overview and application in radiology." Insights into imaging 9.4 (2018): 611-629.
- [7] Neubeck, Alexander, and Luc Van Gool. "Efficient non-maximum suppression." 18th International Conference on Pattern Recognition (ICPR'06). Vol. 3. IEEE, 2006.