

Güvenlik Sistemleri için Silah ve Bıçak Tanıma**Şahin IŞIK¹, Şerif Ercan ÖZKAN², Zühal KURT^{3*}**^{1,2} Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir.³ Atılım Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Ankara.

e-posta: sahini@ogu.edu.tr

ORCID ID: <http://orcid.org/0000-0003-1768-7104>serifercanozkan@gmail.com ORCID ID: <http://orcid.org/0000-0003-3141-3126>

Sorumlu yazar: zuhal.kurt@atilim.edu.tr

ORCID ID: <http://orcid.org/0000-0003-1740-6982>

Geliş Tarihi: 11.11.2020

Kabul Tarihi: 16.06.2021

Öz

Bu çalışma, halka açık yerlerde güvenlik sorunlarının üstesinden gelmek için etkili ve yenilikçi bir çözüm sunmaktadır. Alternatif bir video gözetim sistemi olarak, önerilen yöntem videolardan silah ve bıçak nesnelere gerçek zamanlı olarak algılar ve yerleştirir. Evrimsel Sinir Ağı tabanlı nesne algılama ile bağlantılı olarak, en yüksek performansa sahip silah ve bıçak nesnelere tespit etmek için Hızlı-Bölgesel Tabanlı Evrimsel Sinir Ağı yapısı uygulanmıştır. Test görüntüleri üzerinde simülasyon gerçekleştirdikten sonra, geliştirilen sistemin F1-skor performansı yaklaşık %70 tanıma oranı olarak elde edilmiştir. Eğitilen Faster R-CNN modeli, uçak, otobüs durağı, stadyum ve güvenliğin önemli bir faktör olduğu kamu taşıtları da dâhil olmak üzere farklı halka açık yerler için kullanılabilir. Ayrıca, geliştirilen yöntem, tehlikeli nesnelere raporlanması ve bu tür nesnelere neden olduğu risklerin en aza indirilmesi açısından yerel gözetim sistemine gömülebilir.

Anahtar kelimeler

Silah Tanıma; Bıçak Tanıma; Hızlı-Bölgesel Tabanlı Evrimsel Sinir Ağı; Yerel Gözetim Sistemi

Gun and Knife Detection for Surveillance Systems**Abstract**

This study presents an effective and innovative solution to overcome the security issues/problems in public places. As an alternative video surveillance system, the proposed method detects and localizes gun and knife objects from videos in real-time. In connection with Convolutional Neural Network (CNN) based object detection, the Faster R-CNN structure was applied to detect gun and knife objects with the highest performance. After conducting a simulation on test images, we have found that the F1-score performance of the developed system is about 70% recognition rates. The trained Faster R-CNN model can be utilized for different public places, including airplanes, bus stations, stadiums, and public vehicles, where the security is an important factor. Moreover, the developed method can be embedded in the local surveillance system in terms of reporting dangerous objects as well as minimizing the risks caused by such objects.

Keywords

Gun Detection; Knife Detection; Faster-Regions with Convolutional Neural Networks; Local Surveillance System

© Afyon Kocatepe Üniversitesi

1. Giriş

Günümüzde, insan can ve mal güvenliği hemen hemen tüm toplumların başlıca sıkıntılarının birisi olarak nitelendirilebilir (Int Kyn. 2, 3, 5, 7). Kamera-tabanlı bir güvenlik sistemi uygulanarak; birçok hırsızlık ve suçları önlemek mümkün olmaktadır. Ayrıca, video izleme sistemleri sayesinde hırsızlığın önlenmesinden müşteri hareketlerini tespitine kadar, iş yerlerinde birçok avantaj sağlanmaktadır. Güvenlik kameralarından elde edilen video verilerinden şüpheli hareketlerin tespiti, çocuk

kaçırma olayları veya kaza görüntüleri yapay zekâ tabanlı sistemler ile önceden bulunabilmektedir.

Yapılan bir çalışmada (Tiwari *et al.* 2015) otomatik gözetim sistemi için görsel silah tespiti görevini yerine getirecek bir algoritma geliştirilmiştir. K-ortalama (K-means) algoritması ile imge segmente edilmekte ve daha sonra renge göre silahın olduğu bölge tespit edilmektedir. Segmente edilen bölgelerin silah içerebilecek şekilde olması durumunda Harris köşe bulma algoritması ile önemli

noktalar tespit edilmektedir. Sonra bu noktalar etrafında FREAK betimleyici ile öznelikler çıkarılarak silahın imgedeki olup olmadığı benzerlik oranına göre karar verilmektedir.

Yine başka bir çalışmada (Yuenyong *et al.* 2018) kızılötesi (infrared) görüntülerden bıçağın olduğu imgeler tespit edilmektedir. Şekil 1'de görüldüğü gibi kişi bıçağı gizlese bile kızılötesi kameradan bıçağın olduğu bölgelerin renkleri farklı gözlemlenmektedir. Yuenyong *et al.* 2018'de gerçekleştirdikleri çalışmada yöntem olarak (ESA) Evrişimsel Sinir Ağları (Convolutional Neural Network, CNN) tabanlı olan GoogleNet mimarisi kullanılmıştır. Sistem 4,500 tane bıçak taşımayan ve 3,500 tane bıçak taşıyan veri kümesi üzerinden eğitilmiştir. Test aşamasında 217 tane bıçak taşıyan insanın 211 tanesi doğru olarak sınıflandırılmıştır. Ayrıca geliştirilen sistemde, 310 tane tane bıçak taşımayan kişi üzerinden yapılan deneyde ise 305 kişi doğru olarak sınıflandırılmıştır.

Ayrıca başka bir çalışmada Kırmızı-Yeşil-Mavi (KYM) uzayındaki renkli (RGB) imgelerden bıçağın olduğu bölgeler çerçeve içine alınmaktadır (Buckchash *et al.* 2017). Bu amaç ile önerdiğimiz çalışmada da olduğu üzere, farklı pozlardan çekilmiş bıçak görüntülerini ihtiva eden veri üzerinde eğitim aşaması gerçekleştirilmiştir. Bunun için imgeden öncelikle arkaplan çıkarılmakta, bıçağın olduğu bölgelerden Hızlı (Fast) betimleyicileri ile öznelikler bulunmakta ve son olarak Destek Vektör Makineleri (Support Vector Machine, SVM) ile sınıflandırma işlemi gerçekleştirilmektedir.

Özellikle okullarda, stadyumlarda, havaalanları, otoparklar, devlet dairelerinde saldırganlar ellerinde bıçak ve silahlar ile taşınması durumunda tehlike saçmaktadırlar ve çoğu zaman bu silahları insan gözü ile hemen anında fark etmek mümkün olmamaktadır. Buna benzer birçok olaya her gün televizyon haberlerinde veya gazete manşetlerinde rastlanmaktadır. Bu çalışmada silah ve bıçakların yapay zekânın alt dalı olan görüntü işleme ve makinesi öğrenmesi yoluyla tespiti amaçlanmaktadır. Bu amaç için derin öğrenme tabanlı yaklaşımlarından Evrişimsel Sinir Ağları

kullanılarak sistem eğitilerek tanıma işlemi gerçekleştirilmiştir. Kodlama aşamasında Tensorflow kütüphanesi kullanılmıştır.

Çalışmanın amacı toplum içinde silahlı bir saldırgan varsa bu kişiyi kameralardan anlık olarak tespit edip orada sorumlu olan en yakın güvenlik ekibine bildirmektir. Böylece yerleştirilen kameraların olduğu bölgede güvenlik riskini en aza indirmeye çalışılmıştır. Diğer çalışmalardan farklı olarak; bu çalışmada derin öğrenme teknikleri kullanarak silah ve bıçak tanıma işlemi gerçekleştirilmiştir.

2. Materyal ve Metot

2.1 Ön İşleme ve Veri Kümesi

sınıf	Örnek#01	Örnek#02	... Örnek#n
silah			
bıçak			

Şekil. 1. Silah ve bıçak veri setine ait bazı görseller.

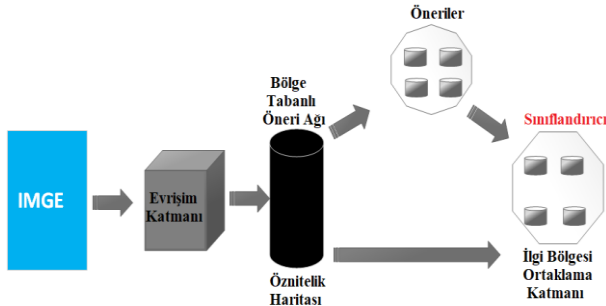
İmgelerinden silah ve bıçak objelerinin yeri belirlenirken labelimg programı (Int Kyn. 4) kullanılmıştır. Objelerin koordinatları *.xml şeklinde kaydedilmiştir. Daha sonra elde edilen *.xml dosyalarını eğitim (train) ve test olmak üzere iki farklı *.csv dosyası halinde saklanmıştır. Silah tanıma için Ganada üniversitesinin araştırma grubuna ait veri kümesi tercih edilmiştir (Int Kyn. 6). Yine bıçak tanıma için 'Knife Image Database' veritabanı kullanılmıştır (Matiolański *et al.* 2016).

2.2 Faster R-CNN Metodu

Güvenlik konusunda geçmiş uygulamalara baktığımızda genellikle X-Ray cihazlar, havaalanında, askeri bölgelerde veya otoparklarda aktif olarak kullanılmaktadır. Buna ek olarak New Jersey eyaletinde bulunan Rutgers Üniversitesi'nde yapılan çalışmalarda kablosuz internet (wifi) sinyalleri ile silahların tespit edilebileceği ortaya çıkmıştır (Int Kyn. 1). Yine başka bir çalışmada (Int Kyn. 7), kızılötesi sinyalleri ile silah tespiti yapan sistem geliştirmiştir. Ama araştırmalarımız

doğrultusunda görüntüler üzerinden silah tespiti yapan sistemlere ilişkin projeler ve çalışmalar çok az sayıdadır.

- Çalışmamızda özgün olarak derin öğrenme yaklaşımlarından Hızlı-bölgesel tabanlı evrimsel sinir ağı (Faster R-CNN) modeli (Ren *et al.* 2015), oluşturduğumuz silah ve bıçak veri kümesi üzerinde yeniden eğitilmiştir.
- Platformdan bağımsız olarak kullanılan Tensorflow python kütüphanesi tercih edilmiştir.
- Eğitilen model, taşınabilir/portatif özelliğine sahip olarak birçok çalışmada kullanılabilecektir.
- Eğitim aşamasında 2.586 bıçak ve 2.287 silah imgesi kullanılarak Faster R-CNN modeli ile eğitilmiştir.
- Ayrıca, validasyon aşaması için 721 tane bıçak ve 557 tane silah imgesi kullanılmıştır.
- Faster R-CNN modeli eğitilirken 150,000 iterasyon, L2 regularizasyon ve Softmax aktivasyon fonksiyonu kullanılmıştır. Optimizasyon işlemi için Olasılıksal Dereceli Azalma Momentum metodu (Stochastic Gradient Descent with Momentum, SGDM) kullanılmıştır.



Şekil 2. Faster R-CNN yapısı.

Önerdiğimiz çalışmanın temelinde derin öğrenme ve nesne tanıma gibi konu başlıkları yer almaktadır. Bu çalışmada bıçak ve silah tanıma işlemini ESA yapılarından olan Faster R-CNN yöntemi ile gerçekleştirilmeye çalışılmıştır. Faster R-CNN ile hedefteki nesnelerin videolarda tespit edilmesinin doğruluk oranı en üst seviyeye taşınmıştır.

Faster R-CNN hız olarak R-CNN algoritmasına (Girshick *et al.* 2014) göre daha hızlı çalışmaktadır. Bölge önerisini selektif/seçici arama ile yapmak yerine, bölge önerisini ağ yapısı (network) içerisinde aramaktadır. Faster R-CNN de girdi/input olarak bir imge almakta ve imgeyi evrimsel sinir ağından

geçirip bir öznitelik haritası çıkarmaktadır. Daha sonra bu aşamada selektif arama ile bölge önerisi almak yerine ayrı bir bölge önerisi ağı oluşturmaktadır. Artık bölge önerilerini bu ağ üzerinde yapmaktadır. Ağ bölgeleri belirlendikten sonra geri kalan işlemler Fast R-CNN ile benzer şekilde gerçekleştirilmektedir.

Belirlenen bölgeler yeniden şekillendirdikten sonra elde edilen öznitelikler tam bağlantılı katmanlardan (fully connected layer) geçirilmekte ve sınıflandırma yapılmaktadır. Bu işlemi gerçekleştirirken eğitim için gereken 4 farklı parametre kullanılmaktadır. Hem bölge önerisi veren ağ eğitilmekte hem de normal konvolüsyonel işlemler yapılan ağ eğitilmektedir. Bölge önerisi yapan ağın 2 tane görevi vardır. Her öneri için orada nesne olup olmadığına karar vermesi gerekmektedir. Aynı zamanda nesnenin tespit edildiği pencere büyüklüğü belirlenmelidir. Faster R-CNN ağı, sınıflandırma işlemini gerçekleştirerek baktığı bölge içerisinde nesne bilgisini çıkarmaktadır. Daha sonra bulunduğu nesnenin sınırlarını belirlemektedir.



Şekil 3. CNN tabanlı silah ve bıçak tanıma sistemi.


Önerdiğimiz sistemin çalışma prensibi Şekil 3'te gösterilmiştir. Öncelikle Faster R-CNN modeli eğitilmektedir. Daha sonra gelen test resimleri ile sistem gerçek zamanlı olarak test edilmektedir.

- Geliştirdiğimiz sistemde eğitilmiş Faster R-CNN modeli her türlü alanda; havaalanı, otogar, stadyum, toplum taşıma araçları ve devlet dairelerinde kullanılabilecektir.

- Oluşturduğumuz model platformdan bağımsız olarak herhangi bir mobil uygulamada veya yazılım dili ile beraber kullanılabilir.
 - Oluşturulan sisteme farklı silah veya tehlike saçabilecek nesnelere eklenerek geliştirilebilir.
- Yerli güvenlik sistemlerine kolaylıkla entegre edilebilir.

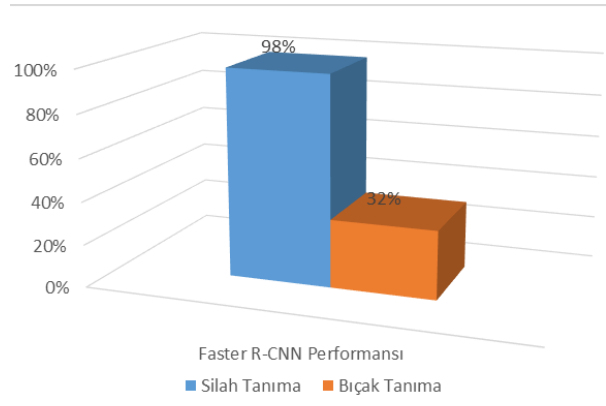
3. Bulgular

3.1 Performans Analizi



Şekil. 4. Silah (gun) ve bıçak (knife) tanıma görsel sonuçları.

Şekil 4'te görüldüğü gibi Faster R-CNN yüksek doğruluk oranıyla silah tanıyabilmektedir. Bıçak tanıma yaparken bazı imgelerden daha düşük performans sergilemektedir. Bunun nedeni bıçak objeleri çok küçük olduğunda Faster R-CNN yapısı tanımakta zorlanmaktadır.



Şekil. 5. Silah ve bıçak tanıma üzerine sayısal sonuçlar.

Şekil 5'te Faster R-CNN modelinin sayısal olarak performans analizi yapılmıştır. Bunun için 50 bıçak imgesi ve 50 silah imgesi test olarak kullanılmıştır. Eşik değeri 70% oranına göre silah veya bıçak bulma skorları not edilmiştir. Elde edilen skora göre silah tanıma 90% performans ile yapılmaktadır. Diğer yandan bıçak tanıma işlemi 32% doğruluk oranıyla gerçekleştirilmiştir.

Çizelge. 1. 100 imge için silah ve bıçak tanıma sonuçları.

Ölçütler	Değer
Doğruluk (Accuracy): Silah	90%
Doğruluk (Accuracy): Bıçak	32%
F1-Skor	69.76%
Kesinlik (Precision)	56.96%
Duyarlılık (Recall)	90.00%
TP	45
FP	34
TN	16
FN	5

Önerdiğimiz sistemin doğruluk, kesinlik, duyarlılık ve F1-skor değerleri Çizelge 1'de verilmiştir. Toplam 100 imge üzerinden yapılan deneylerde True Positive (TP), False Positive (FP), True Negative (TN) ve False Negative (FN) değerleri üzerinden kesinlik ve duyarlılık ölçütleri hesaplanmıştır. Yapılan ölçümlere göre önerdiğimiz sistemde yaklaşık olarak 70% oranında F1-skor değeri elde edilmiştir. False Negative değeri ise 5 olarak bulunmuştur.

4. Tartışma ve Sonuç

Bu çalışmada, Tensorflow nesne tanıma kütüphanesi kullanılarak gerçek zamanlı bıçak ve silah tanıma uygulaması geliştirilmiştir. Elde edilen sonuçlar incelendiğinde gerçek imgeler üzerinde eğitilmiş Faster R-CNN modeli kullanılarak yüksek performans ile bıçak ve silah tanıma işlemi

gerçekleştirilmiştir. Aynı zamanda hızlı bir şekilde imgelerden elde edilen bıçak veya silah bölgeleri çerçeve içine alınabilmektedir. Geliştirilen model yaklaşık olarak %70 oranında F1-skor ölçütü değeriyle bıçak ve silah tanıyabilmektedir.

İlerleyen çalışmalarda elde edilen Tensorflow modeli bir mobil uygulamaya veya gerçek zamanlı olarak çalışacak şekilde gömülü bir sisteme entegre edilebilir.

5. Kaynaklar

Buckchash H. and Raman B., 2017, A robust object detector: application to detection of visual knives, International Conference on Multimedia & Expo Workshops, IEEE2017, 633-638.

Girshick R., Donahue J., Darrell T. and Malik J., 2014. Rich feature hierarchies for accurate object detection and semantic segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 580-587.

Matiolański A., Maksimova A. and Dziech A., 2016. CCTV object detection with fuzzy classification and image enhancement, *Multimedia Tools Applications*, **75**, 10513-10528.

Ren S., He K., Girshick R. and Sun J., 2015. Faster R-CNN: Towards real-time object detection with region proposal networks, *Advances in Neural Information Processing Systems*, 91-99.

Tiwari R.K. and Verma G.K., 2015. A computer vision based framework for visual gun detection using harris interest point detector, *Procedia Computer Science*, **54**, 703-712.

Yuenyong S., Hnoohom N. and Wongpatikaseree K., 2018. Automatic detection of knives in infrared images, *Int. ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering*, IEEE2018, 65-68.

İnternet kaynakları

1- bbc.com, <https://www.bbc.com/turkce/haberler-dunya-45195900>, (05-06-2021).

2- everytownresearch.org, <https://everytownresearch.org/gun-violence-america/>, (05-06-2021).

3- Hurriyet.com, <http://www.hurriyet.com.tr/kelebek/saglik/her-yil-3-bin-kisi-silahla-oluyor-27289543>, (05-06-2021).

4- labeling, <https://github.com/tzutalin/labelImg>, (05-06-2021).

5- nytimes.com, <https://www.nytimes.com/2018/12/18/us/gun-deaths.html>, (05-06-2021).

6- weapons-dataset, <https://sci2s.ugr.es/weapons-detection>, (05-06-2021).

7. youtube.com, <https://www.youtube.com/watch?v=qV6hy28C8-8>, (05-06-2021).