International Marmara Sciences Congress
(Imascon 2022 Spring)

13 – 14 May 2022 KOCAELI

PROCEEDINGS
E-BOOK

Organizer

Sponsors

This congress proceedings book is published as an electronic format as e-book.

All rights reserved.

Editorial Board

Prof.Dr. Arif ÖZKAN
Assoc.Prof.Dr. Serdar BİROĞUL
Assoc.Prof.Dr. Ömer GÜNGÖR
Lect. İsmail KILIÇASLAN
Lect. Kazım KAHRAMAN

ISBN: 978-605-70762-4-3

Address Kocaeli Üniversitesi Rektörlüğü, Umuttepe Yerleşkesi Kocaeli, TÜRKİYE
Phone +90 262 303 1000
E-mail info@imascon.com
Web www.imascon.com

All legal and ethical responsibility of the studies belongs to the authors. All rights reserved. The copyright of this proceedings book belongs to Kocaeli University. It may not be copied or reproduced without permission.

DERİN ÖĞRENME YAKLAŞIMLARI İLE GÖMÜLÜ SİSTEMLER İÇİN GERÇEK ZAMANLI ARAÇ SAYIM VE TAKİP SİSTEMİ 544

DALGA ENERJİSİ VE GÜNEŞ ENERJİSİNDEN ELEKTRİK ÜRETİMİNİN ZONGULDAK İLİ ÖZELİNDE KARŞILAŞTIRILMASI 551

BİR BOYUTLU FOTONİK KRİSTAL YAKININDA İKİ KÜRESEL PARÇACIĞIN OPTİK YANITI 561

GALVANO MANYETİK KUVVET ÖLÇME CİHAZLARI VE UYGULAMA ALANLARI 565

CONSEQUENCES OF COVID-19 ON FOREIGN DIRECT INVESTMENT 573

NANO-DELİKLİ PLAZMONİK ANTEN TABANLI PEROVSKİTE GÜNEŞ PİLİ TASARIMI 580

REZONATÖR TİP KUVVET ÖLÇÜM CİHAZLARI VE DİĞER SENSÖRLERE GÖRE FARKLILIKLARI 585

MANYETİK KAÇAK AKI SİSTEMİNİN MANYETİK EŞDEĞER DEVRE VE SONLU ELEMANLAR YÖNTEMİ İLE ANALİZİ 592

M3 SINIFI ELEKTRİKLİ BİR ARAÇ İÇİN ELEKTRO HİDROLİK DESTEKLİ DİREKSİYON SİSTEMİ GELİŞTİRİLMESİ 597

L7 SINIFI MİKRO ELEKTRIKLI ARAÇ TASARIMI VE YANAL TAŞIT DİNAMİĞİ OPTİMİZASYONU 603

GÜÇ SİSTEMLERİNDE HARMONİK YÜK TESPİTİ İÇİN KULLANILAN V-I ORANI YÖNTEMİNİN İNCELENMESİ 609

UYUMLU MESH-GRİD ŞEKİLLİ FREKANS SEÇİCİ YÜZEY (FSY) KULLANILARAK SİLİNDİRİK NESNELER İÇİN MANTO PELERİNİNİN ANALİZİ VE GERÇEKLEŞTİRİLMESİ 615

BOOST DÖNÜŞTÜRÜCÜ DEVRESİNİN DURUM-UZAY ORTALAMA TEKNİĞİNE DAYALI GEÇİCİ-HAL VE SÜREKLİ HAL ANALİZİ 622

SYNTHESIS OF NOVEL CALIX[4]ARENE SCHIFF BASE DERIVATIVE AND INVESTIGATION OF ITS ANTIPROLIFERATIVE EFFECTS AGAINST DIFFERENT CELLS 628

SİNYALİZE BİR KAVŞAKTA V2X İLE ACİL DURUM ARACI ÖNCELİKLENDİRME ANALİZİ 633

IMASCON 2022 SPRING SESSION 6.3 / 12:00 – 13:15	Hall : 3	14 MAY 2022
SESSION CHAIR : Dr. Bülent KOPARAN		
Zahraa Faris ALAANI	Deep Reinforcement Learning Based Dynamic Resource Allocation In 5g Networks	
Basel ZIDAN	Load Tracking System	
Ramazan CENKER	The İmpact of Orbital Divergences to Multimedia Security	
Abdulrezzak DURAN	Real-time vehicle counting and tracking system with deep learning approaches for embedded systems	
Sare Nur ÇUHADAR	Perovskite Solar Cell Design Based on Nano-Hole Plasmonic Antennas	
Mohamed Moussa Farah	Geology and Trace Element Geochemistry of the Barite Mineralization in the North of Kocaeli	
ONLINE PRESENTATIONS		
14 MAY 2022	**SESSION 7**	**Time 13:30 – 14:45**
IMASCON 2022 SPRING SESSION 7.1 / 13:30 – 14:45	**Hall : 1**	**14 MAY 2022**
SESSION CHAIR : Assist Prof.Dr. Serpil ÖZKURT SİVRİKAYA		
Cabir KÜÇÜK	The Latest Status Of Renewable Energy Production In Turkey	
Esra AYDIN	Performance Analysis of a Photovoltaic Power System with Energy Storage Using PvSOL Software	
Muhammed Selman EREL	Computational Speed Performance Comparison Of Fast Fourier Transform Libraries In 2d	
Museyib HABIBLI	Single Phase High Frequency Inverter Design For Wireless Charging Systems	
Assoc.Prof.Dr. Edmond HOXHA	Mining Industry After Covid-19	
IMASCON 2022 SPRING SESSION 7.2 / 13:30 – 14:45	**Hall : 2**	**14 MAY 2022**
SESSION CHAIR : Dr. Asım ZEYBEK		
Dr. Asım ZEYBEK	The Effect of Pre-Aging on Hardness Response of Naturally and Artificially Aged 6082 Aluminium Alloy Extrusions	
Dr. Asım ZEYBEK	The Effect of Cooling Rate on Coloration of Different Anodized Aluminium Alloy Extrusions	
Elif TÜREDİ	The Effect Of The Use Of Different Material On The Quality Of The Parts In The Manufacturing Of The Sealing Element Used In Pipe Connection Lines In Injection Molds	

DERİN ÖĞRENME YAKLAŞIMLARI İLE GÖMÜLÜ SİSTEMLER İÇİN GERÇEK ZAMANLI ARAÇ SAYIM VE TAKİP SİSTEMİ

Abdulrezzak DURAN, Fevzi DERELİ, Ayhan KÜÇÜKMANİSA, Ramazan DUVAR, Oğuzhan URHAN

Özet

Günümüzde gelişen görüntüleme teknolojileri sayesinde devletlerin güvenlik ve denetleme amaçlarıyla kullandıkları görüntüleme sistemleri ile sivillerin kaydettiği video içerikler artmıştır. Bunun bir sonucu olarak da oluşturulan büyük ölçekteki verinin otomatik şekilde işlenmesi gereksinimi nedeniyle nesne tespiti algoritmalarına olan ilgi ve bu konuda yapılan araştırmalar buna paralel şekilde artmıştır. Bu çalışmada araç ve yaya sınıflandırma amacıyla derin öğrenme temelli nesne tespit yaklaşımlarından olan YOLOv4, YOLOv5 ve EfficientDet yöntemleri kullanılmış ve bu nesne tespit yaklaşımlarının performansları kıyaslanarak probleme en uygun yaklaşımın tespit edilmesi amaçlanmıştır. Böylece en uygun yöntem seçilerek araç trafiğine açık rotalarda denetleme amaçlı görüntüleme sistemleri, anlık veya belirli bir zaman diliminde yoldan geçen farklı tiplerdeki araç ve yaya sayısının tespitini ve takibini yapabileceklerdir. Bu çalışma kapsamında son olarak önceden test edilen ve karşılaştırılan tespit yöntemleri ve sayım algoritması düşük maliyetli işlem birimleriyle gerçek zamanlı olarak çalıştırılmış ve performansları incelenmiştir. Elde edilen bu sonuçlar bu tip sistemlerin kara yollarında, şehir içi yollarda ve otoparklarda kullanıma uygun olan sistem gömülü sistemler üzerinde gerçek zamanlı çalışabilecek performansta ve başarımda olduğunu göstermiştir. Karşılaştırma sonucunda F1 skoru açısından en başarılı yöntem YOLOv5, çalışma hızı olarak en başarılı yöntem YOLOv4 bulunmuştur.

Abstract

Thanks to the developing imaging technologies, the imaging systems used by the governments for security and surveillance purposes and the video contents captured by civilians have increased. As a result of this, due to the need for automatic processing of large-scale generated data, the interest in object detection algorithms and researches on this subject have increased. In this work, YOLOv4, YOLOv5 and EfficientDet methods which are deep learning based object detection approaches are used for vehicle and pedestrian classification. In this study, it is aimed to determine the most appropriate method to the problem by comparing the performances of these object detection approaches. Thus, by selecting the most appropriate method, they will be able to identify and track the number of vehicles and their types and pedestrians crossing the road in real time or specific time period for inspection purposes on any roads. Finally, within the scope of this study, the deep learning methods and the counting algorithm are employed in real time and their performances are examined. These results show that this type of systems has the performance and accuracy to work in real time on embedded systems, which are suitable for use on highways, urban roads and parking lots. As a result of this work, the most accurate method in terms of F1 score is found as YOLOv5, the fastest method in terms of processing speed is found as YOLOv4.

Giriş

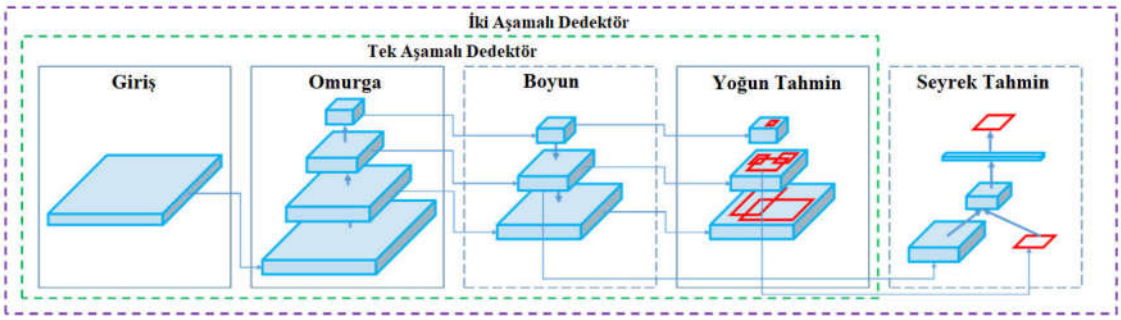
Araç tespiti, araç tanıma ve sınıflandırma hem akıllı taşıma sistemleri için hem de denetleme sistemleri için gelişmekte olan önemli bir alandır. Üzerinden geçen araçları sayan manyetik döngü tabanlı sensörler veya ultrasonik dedektörler trafik parametrelerini takip edebilmek için kullanılmaktadır. Bu sistemlere karşılık olarak görüntü işleme tabanlı sistemler bir dizi avantaj sunmaktadır. Görüntü işleme ve derin öğrenme tabanlı sistemler sadece araçları saymakla kalmaz, bunlara ek olarak araçları sınıflarına göre ayırabilmeyi ve şerit değişiklikleri sıklığını tespit edebilmeyi mümkün kılmaktadır. Bunlara ek olarak montajları ve bakımları diğer sensörlere göre daha az masraflıdır (Gupte ve diğ., 2002; Zhou ve diğ., 2007). Kameralardan alınan görüntüler ile trafik takibi ve araç sayımı işlemleri görüntü işleme yaklaşımlarıyla yapılabilmektedir. Başarılı görüntü işleme uygulamaları ortamın tüm koşullarında çalışabilmelidir. Araç ve yaya tespiti için temel zorlayıcı koşullar ortam aydınlatması ve hava şartlarıdır. Bunlara ek olarak araçların farları da çoğu durumda nesne tespitini zorlaştırmaktadır. Örneğin gece saatlerinde araçların farları yolu aydınlatmaktadır ve görüntü işleme temelli sistemlerin tespit etmesi gereken araçların kameraya gelen görüntüsü yola göre çok daha az aydınlık olacağı için farlar büyük ölçüde gürültüye sebep olurlar ve bu da tespit işini zorlaştırmaktadır (Liu ve diğ., 2013).

Nesne Tespiti

Nesne tespiti, bilgisayar görüsünün bir alt dalıdır ve bilgisayarların da nesneleri insanlar gibi tanımasına ve sınıflandırmasına denmektedir. Çoğu bilgisayar görüsü uygulaması gibi (nesne tespiti, nesne takibi) nesne sınıflandırma da zor ve önemli bir görevdir ve diğer bilgisayar görüsü uygulamalarının genelde temelini oluşturmaktadır. Nesne sınıflandırma ile nesne tespiti farklı şeylerdir; nesne tespiti görüntüde belirli bir nesnenin aranması ve bulunması durumunda konumunu söyleyen uygulamaya denmektedir, nesne sınıflandırma ise var-yok bilgisi aranmaksızın imgeye daha önce öğretilmiş nesnelerin (veya matematiksel kuralların) sınıflarının benzerliğine bir skor verme işlemidir. İnsanlar için oldukça kolay olan bu işlemler bilgisayarlar için büyük bir sorundur. Bu sorunun çözümü için bilgisayar bilimleri alanında makine öğrenmesi tanıtılmış ve uygulanmaya başlanmıştır. Akabinde özellikle sabit nesnelerde kötü olmayan sonuçlar elde edilmiştir (Sarkale ve diğ, 2018). Bu çalışma kapsamında araç ve yaya sınıflandırma problemi bir nesne tespit problemi olarak ele alınıştır.

YOLOv4 Yöntemi

Tipik bir nesne tespit etme mimarisi giriş, omurga, baş ve boyun olmak üzere dört temel bileşenden oluşur. Omurga kısmında önceden eğitilmiş ağ bulunur ve bu kısımda alınan giriş imgesinden özellik çıkarma işlemi gerçekleştirilir; kafa kısmında nesnenin tespitinin yapılması ve sınıfının tahmin edilmesi işlemleri yapılır. Boyun kısmı da daha gelişmiş filtreler kullanılarak ara aşamalarda çıkarılan özellikleri toplayarak gürbüzlüğü arttırma amacına hizmet eder. Şekil 1'de YOLOv4 mimarisi gösterilmiştir.

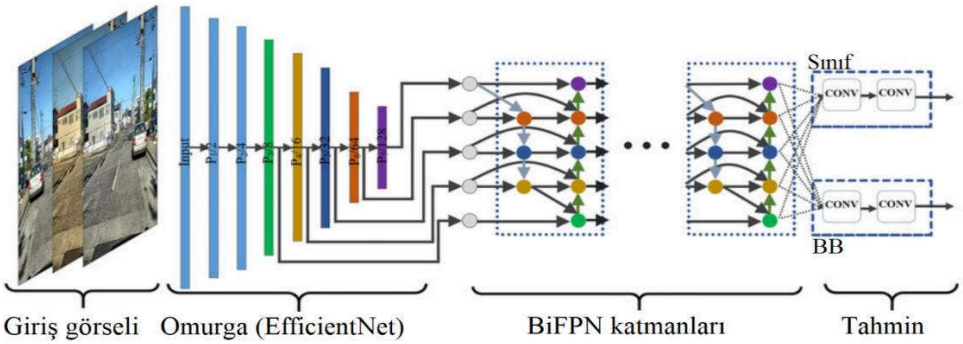


Şekil 1: YOLOv4 Mimarisi (Bochkovskiy ve diğ., 2020)

YOLOv4, önceki versiyonlarına göre gürbüzlüğü arttırmak amacıyla geliştirilmiş, daha modüler ve dolayısıyla daha esnek bir yapıdadır. Daha yüksek başarım elde etmek için daha derin bir ağ sistemi tasarlayan araştırmacılar, Dense (her nöronun bir önceki ve bir sonraki katmanda bulunan tüm nöronlara bağlantılı olma şekli) bloklar kullanmıştır. Yığın normalleştirme işleminden sonra birden fazla evrişimsel katman içeren sistemin bu katmanlarının çıkışında aktivasyon fonksiyonu olarak ReLU (doğrultulmuş doğrusal birim) seçilmiştir. CSP (durum çapraz bölücü), giriş katmanındaki özellik haritalarını ikiye böler; bir kısmı direkt olarak daha sonraki katmana diğeri ise doğrudan Dense bloğa geçer, ki bu bloktaki hesaplama maliyeti diğerlerine oranla daha yüksek olduğundan ve tüm özellik haritaları bu katmana girmediğinden ötürü sistemin hesap yükü azalmakta ve performans artışı sağlanmaktadır.

EfficientDet Yöntemi

EfficientDet, diğer birçok nesne tespiti yöntemleri gibi hem başarıma hem de performansa odaklanmakta ve bunu maksimize etmek istemektedir. Araştırmacıların bu amaçlarını gerçekleştirebilmek için öncelik verip üstüne eğildikleri birkaç konu bulunmaktadır. Bunlardan ilki verimli bir çok ölçekli özellik füzyonudur. Diğer çalışmaların çoğunda giriş imgesinden çıkartılan özellikler birleştirilirken direkt olarak toplanmaktadır fakat araştırmacılar bu özelliklerin füzyon çıktı özelliğine eşit olmayan bir şekilde katkıda bulunduğunu gözlemlemiştir; bunun sebebinin de giriş özelliklerinin neredeyse her zaman farklı çözünürlükte olması olduğunu düşünmektedirler. Bu sorunun çözümü için de basit ve verimli bir yöntem olan çift yönlü ağırlıklandırılmış özellik piramit ağını önermektedirler, bu ağ giriş özelliklerini ağırlıklandırabildiği için her özelliğe aynı önemi vermemekte ve daha akılcı bir çok ölçekli bir özellik birleştirme yöntemi elde edilmiş olmaktadır (Tan ve diğ., 2020). Şekil 2'de EfficientDet mimarisi görülmektedir.

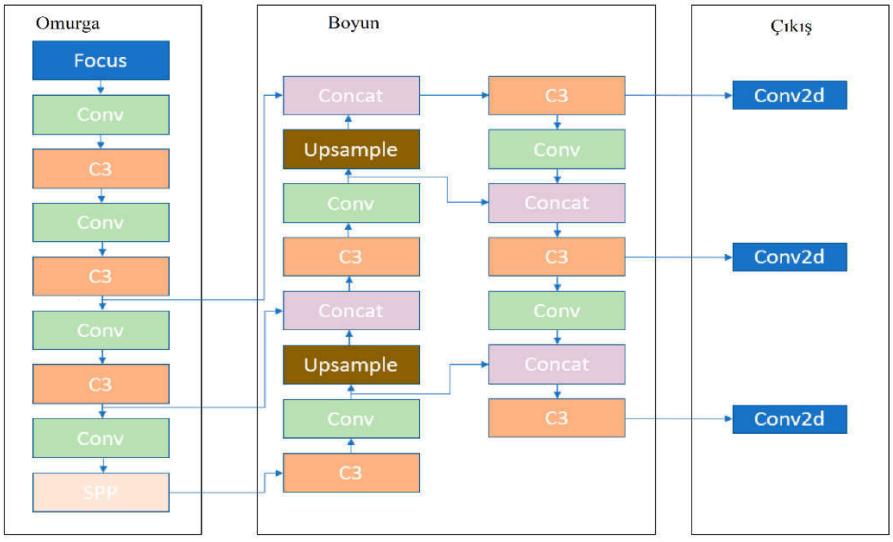


Şekil 2: EfficientDet mimarisi (Tan ve diğ., 2020)

Araştırmacıların diğer üzerine düştükleri konu ise model ölçeklendirmedir. Önceki çalışmalarda doğruluğu arttırmak için giriş imgesinin boyutu büyük seçilse de, bu çalışmada araştırmacılar verimlilik ve doğruluk konusunda özellik ölçeklendirmenin sınıf tahmininde büyük önem taşıdığını gözlemlemiştir. Bunun için de araştırmacılar çözünürlüğün, derinliğin ve genişliğin birlikte ölçeklendirildiği bileşik bir tespit yöntemi önermektedir (Tan ve diğ., 2020). Ölçekleme katsayısı da hız ve performansı etkilemektedir. D0 en hızlı çalışan ölçekleme durumunu, D7 ise en yüksek doğrulukla çalışan katsayının kullanıldığını göstermektedir. Aynı araştırmacıların daha önceki çalışması olan EfficientNet (Tan ve Le, 2019) omurgası ile BiFPN ve bileşik ölçeklendirme yöntemi birleştirildiğinde ortaya çıkan EfficientDet, tutarlı performans veren bir nesne sınıflandırma yöntemi olarak karşımıza çıkmaktadır.

YOLOv5

Diğer YOLO versiyonlarının aksine özgün geliştiricileri tarafından geliştirilmeyen bu versiyon, özellikle mobil cihazlarda kolay eğitim ve yüksek performansa çalışma vadetmektedir. YOLOv3 ve YOLOv4 tabanlı bu sistem, tıpkı EfficientDet gibi bileşik ölçekli bir tespit algoritması içermektedir. Doğruluk için YOLOv4 üzerinde yaptıkları değişikliklerin hepaplama maliyetlerini dengelemek için geliştiriciler CSPNet (Cross State Partial Net) kullanmıştır. Ayrıca ağdaki optimizasyonları sayesinde ağırlık dosyaları büyük ölçüde azaltılmıştır. EfficientDet gibi birden fazla versiyonu olan sistem, “s”, “m”, “l” ve “x” versiyonlarına sahiptir. “s” en hızlı fakat en düşük başarıma sahip olan model iken x en çok işlem gücü gerektiren fakat en yüksek başarıma sahip model olarak tanımlanmıştır. Geliştirilmesi hala devam etmekte de olsa şimdiden perfomans ve geliştirme kolaylığı açısından test edilebilir olduğu düşünülmüştür. Şekil 3’te YOLOv5 mimarisi görülmektedir.



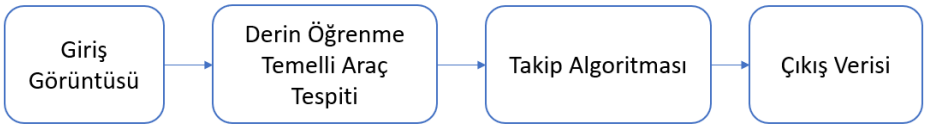
Şekil 3: YOLOv5 Mimarisi (Nepal ve Eslamiat, 2022)

Gömülü Sistemler

Gömülü sistemler bilgisayarların gerçekleştirdikleri işleri daha düşük hacim ve güç tüketimi ile gerçekleştirmeleri için tasarlanmışlardır fakat bilgisayarlara göre daha farklı bir mimariye sahip olmaları ve depolama, işlem kapasitesi gibi parametrelerde limitli kaynaklara sahiptirler. Bu nedenle gömülü sistemler için yazılım geliştirmenin kendine has zorlukları bulunmaktadır. Günümüzde gelişmekte olan bir alan olan gömülü sistemler, bilgisayar ortamı yeteneklerine sahiptir, ancak her gömülü sistemin kendi tasarım ve yazılım geliştirme ortamı vardır, bu nedenle gömülü sistem cihazlara yazılım geliştirmenin kendisi bir araştırma ve geliştirme alanı haline gelmiştir. Gömülü sistemler mimari, bellek, giriş/çıkış birimleri, donanım özellikleri ve ilgili yazılım bileşenlerine göre birçok değişiklik gösterebilirmektedir. Günümüzde en yaygın gömülü sistem mimarisi olan ARM ile birçok firma çeşitli cihazlar üretmektedirler.

ÖNERİLEN YÖNTEM

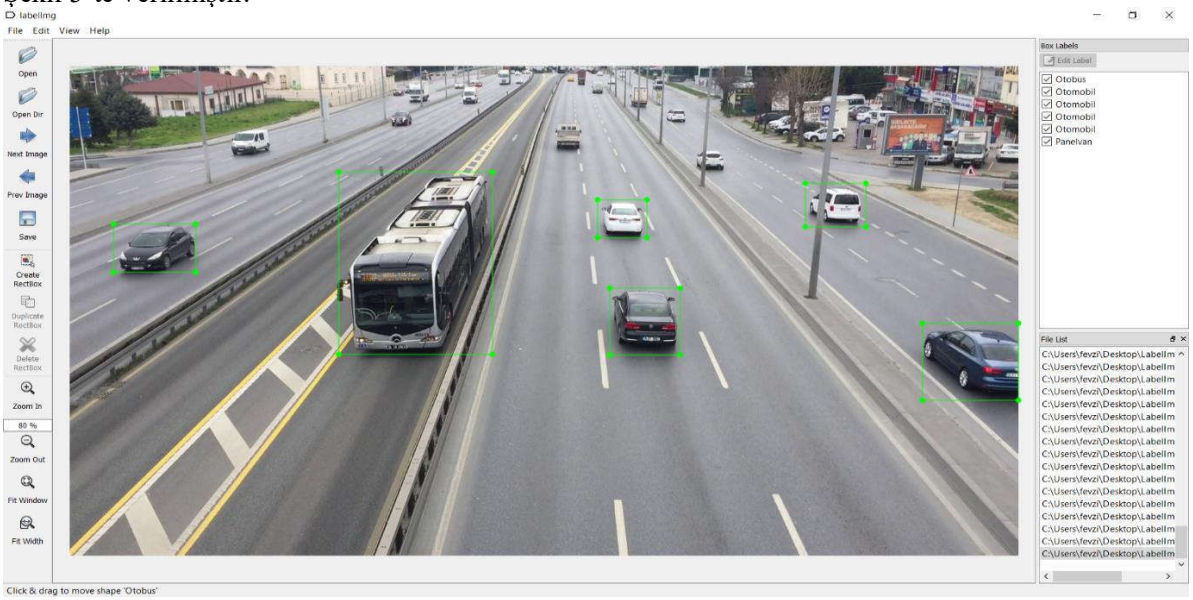
Yöntem ve çalışmalar bölümü üç ana aşamadan oluşmaktadır. İlk olarak ağların eğitimi için ihtiyaç duyulan verinin oluşturulması ve etiketlenme işlemi anlatılmıştır. Devamında test edilen yöntemlerin eğitim sürecinden bahsedilmiştir. Bölüm 2.3'te araç takip sistemi ve son olarak da araç sayım sistemi anlatılmıştır. Şekil 4'te önerilen yöntemin akış şeması verilmiştir.



Şekil 4: Önerilen yöntemin akış şeması

Veri Setinin Oluşturulması

Çalışma sonunda elde edilmesi beklenen sistemin görüntüyü alacağı kamera yüksekteki bir platformdan açılı bir şekilde kendisinden aşağıda bulunan yola bakmakta, bu sayede yol üzerinden geçen yaya ve araçları sınıflandırabilmektedir. Bunun için gereken veri seti de en optimum performans için bu şekilde bir düzenek ile toplanmalıdır. Bu çalışma için İstanbul-İzmit karayolundaki köprülerin üzerinden 1920×1080 çözünürlüğünde saniyede 30 kare içeren video kayıtları toplanmıştır. Aşırı öğrenmeden kaçınabilmek için görüntüleri farklı zaman dilimlerinden ve hava koşullarından elde edilmiştir fakat kameranın yola uzaklığı, bakış açısı gibi parametreler sabit tutulmaya çalışılmıştır. Daha sonra bu kayıtlar kare kare ayrılarak toplamda 7 farklı araç sınıfı (kamyon, otobüs, panelvan, tır, motosiklet, kamyonet, otomobil) ve yaya olarak (toplamda 8 sınıf) etiketlenmiştir. Etiketleme işlemine bir örnek Şekil 5'te verilmiştir.



Şekil 5: Nesne etikleme çalışmasından bir örnek

Eğitilecek olan ağın her sınıfı eşit şekilde öğrenebilmesi için eğitim verisinide her sınıfta 2000 örnek vardır. Bazı sınıflardan yeterince veri elde edilemediği için (özellikle yol kenarındaki yaya sayısının yoldan geçen araç sayısına göre oldukça düşük kaldığı gözlemlenmiştir) ek olarak başka bir çalışmanın veri setinden (Sochor, 2019) de faydalanılmıştır. Veri etiketlemede kullanılabilecek açık kaynaklı birkaç farklı etiketleme aracı bulunmaktadır (LabelImg, BBox, Fast Annotation Tool, ImageTagger, LabelMe gibi); bu çalışmada direkt olarak YOLO formatına etiketleme yeteneği için için LabelImg seçilmiştir ve toplam 10.000'i aşkın imge yaklaşık bir ayda işaretlenmiştir.

Eğitim

Bu çalışma kapsamında eğitim işlemi 2 adet NVIDIA 2080 GPU (Graphics Processing Unit) üzerinde gerçekleştirilmiş olup, işletim sistemi olarak Ubuntu 16.04 kullanılmıştır. Hesaplama işlemlerininin hızlanması ve donanımın performansından tamamen faydalanılabilmesi için grafik sürücüsü CUDA ile birlikte yüklenmiştir. Bu sayede eğitim aşamasında GPU hesaplamalarına ihtiyaç duyulduğunda CUDA devreye girebilmekte, bu da eğitim süresinin düşmesini sağlarken geliştirme sürecinin hızlanmasını sağlamaktadır (Ghorpade, 2012). Tüm ağların performansını eşit kritlerler ile kıyaslayabilmesi için tüm ağların eğitim sırasında kullanılan hiperparametreler Tablo 1'de verilmiştir. Bu parametreler deneysel çalışmalar sonucu elde edilmiştir.

Tablo 9: Modellerin Eğitim Parametreleri

Parametre adı	**Değer**
Eğitim adımı	30000
Öğrenme oranı (learning rate)	0.0261
Düşüş (decay)	0.0005
Momentum	0.949
Batch boyutu	16

Yön tespiti

Aracın tespit edildiği ilk karede aracın merkez noktası belirlenmeye çalışılmaktadır. Bu merkez noktası, aracın tespiti esnasında etrafına çizilen sınırlayıcı kutunun merkezidir. Fakat nesne tespit ağının çizdiği sınırlayıcı kutu, aracı kusursuz bir şekilde çerçeveleyememektedir, bunun sebebi hem ağ eğitiminde kullanılan etiketlenmiş verinin etiketlerinin kusursuz bir şekilde çizilmemiş olması, hem de ağın başarımının %100.0 olmamasıdır. Bu nedenle aracın etrafına çizilen sınırlayıcı kutuya aracın merkezi değil aracın ağırlık merkezi denmiştir. Aracın ağırlık merkezi, x ve y koordinatlarını içeren bir değişkendir. Bir sonraki karede tekrar tespit edilen aracın ağırlık merkezleri arasındaki fark da iki boyutlu bir datadır, bu data kameranın konumuna göre yorumlanarak aracın yönü tayin edilebilir. Örneğin kamera araçların önünü veya arkasını görecek (yola dik) bir şekilde bakıyorsa, sabit olmayan bir aracın yönünü tespit etmek için ağırlık merkezinin y bileşenine bakmak yeterlidir, alınan karenın orijini sol-üst kabul edildiğinde ağırlık merkezinin y bileşeninin pozitif olması aracın kameraya yaklaştığını, negatif olması aracın kameradan uzaklaştığını göstermektedir.

DENEYSEL SONUÇLAR

Kıyaslama sonuçlarının nesnel bir şekilde karşılaştırılabilmesi için aşağıdaki parametreler hesaplanmıştır. TP: konumu ve sınıfı doğru tespit, FP: konumu veya sınıfı yanlış tespit, FN: eksik tespit anlamına gelmektedir. Testler NVIDIA Jetson NANO üzerinde gerçekleştirilmiştir. Hassaslık hesabı pozitif tespitlerin doğruluğunun oranını vermektedir ve matematiksel olarak denklem 3.1'deki gibi hesaplanmaktadır:

$$\text{Keskinlik} = TP / (TP + FP) \quad (3.1)$$

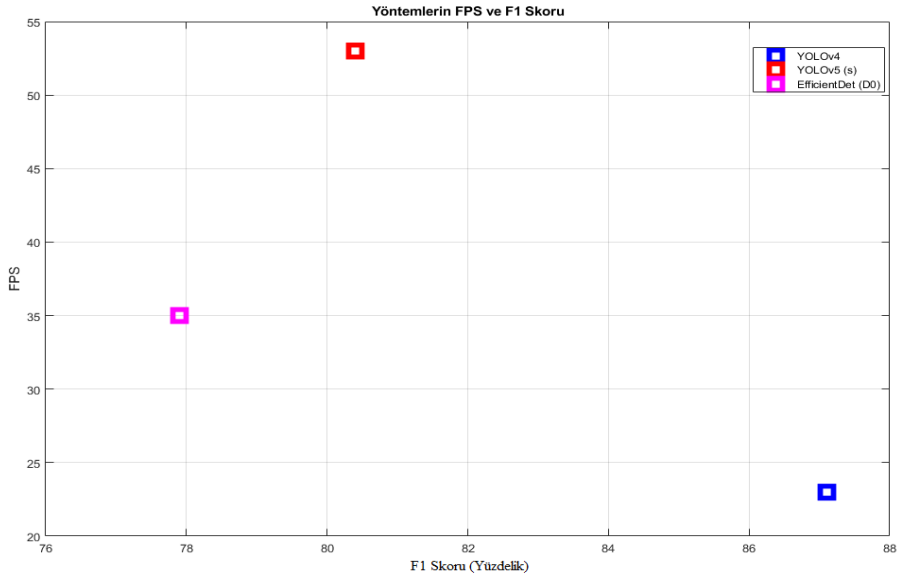
Hatırlama (recall) hesabı pozitif tespitlerin olması gereken tüm potansiyel tespitlere oranını vermektedir ve denklem 3.2'de verilmiştir:

$$\text{Hassasiyet} = TP / (TP + FN) \quad (3.2)$$

F1 Skoru keskinlik ve hassasiyet arasındaki dengenin korunmasını sağlar, keskinlik ve hassasiyetin harmonik ortalamasıyla denklem 3.3'deki gibi hesaplanmaktadır:

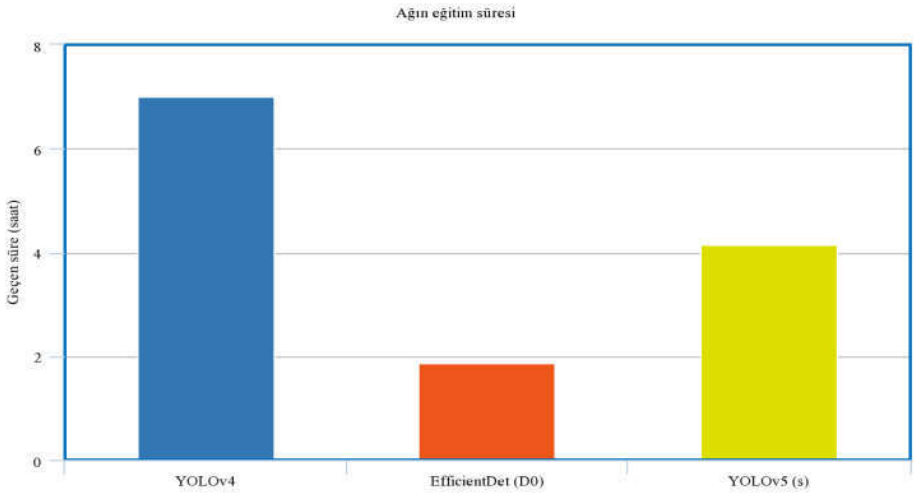
F1 Skoru = 2 × (Keskinlik × Hassasiyet) / (Keskinlik + Hassasiyet) (3.3)

Modellerin performans karşılaştırması Şekil 6'da verilmiştir.



Şekil 6: Modellerin performans karşılaştırması

Şekil 7'de görüldüğü gibi YOLOv4 en uzun eğitim süresine sahipken EfficientDet en kısa eğitim süresine sahiptir.



Şekil 7: Modellerin eğitim süresi karşılaştırması

SONUÇLAR VE ÖNERİLER

Araç sınıflandırma işlemlerinde içi çeşitlilik olduça yüksek olduğu için (aynı sınıftaki arabalar çok farklı şekilde boyaya, cam filmlerine ve modifiyelere sahip olabilirler) bu işlemler diğer sınıflandırma işlerinden farklılaşmaktadır. Bununla birlikte ve sınıflar arası benzerlik oldukça yüksek olup (birçok araç kameranın gördüğü açıya göre oldukça benzeyebilmektedir) araçların sabit bir şekli yoktur. Bunlara ek olarak diğer sınıflandırma uygulamalarıyla karşılaştırıldığında arka planın oldukça değişken olduğu gözlenmektedir. Karşılaştırılan bu yöntemlerde hız ve performans birlikte dikkate alındığında YOLOv5'in daha optimum bir model sunduğu görülmekte birlikte henüz gelişmekte olan bir model olmasından dolayı başarımın birincil hedef olduğu durumlarda YOLOv4'ün ön plana çıktığı

görülmektedir. EfficientDet ise sağlamış olduğu kısa eğitim süresi sayesinde temel çalışmaların ilk yürütülebileceği model olarak değerlendirilmektedir. Bu çalışmada çeşitli şekillerde elde edilen ve etiketlenen 20 bin civarında imge işaretlenmiştir ve başta YOLOv4 olmak üzere birkaç farklı ağda eğitilmiş ve performansları karşılaştırılmıştır. Bu çalışma kapsamında sistem NVIDIA Jetson Nano ve Jetson NX gibi düşük güç tüketimli gömülü sistem cihazlarına entegre edilmiş ve gerçek zamanlı çalıştırılmıştır. Gelecek çalışmalarda YOLOv4 modeli üzerinde optimizasyon çalışmalarının yapılması planlanmaktadır.

REFERANSLAR

Bochkovskiy, A., Wang, C-Y., Liao H-Y. M. (2020). "Yolov4: Optimal Speed And Accuracy Of Object Detection", arXiv preprint arXiv:2004.10934.

Ghorpade., J. (2012). "GPGPU Processing in CUDA Architecture", *Advanced Computing: An International Journal (ACIJ),* 3(1), 105-120

Gupte, S., Masoud, O., Martin, R.F.K., Papanikolopoulos, N.P. (2002). "Detection and classification of vehicles", *IEEE Transactions on Intelligent Transportation Systems,* 3(1), 37-47.

Liu, C., Chang, F. (2019). "Hybrid cascade structure for license plate detection in large visual surveillance scenes", *IEEE Trans. Intell. Transp. Syst.*, 20(6), 2122-2135.

Nepal, U., Eslamiat, H. (2022). "Comparing YOLOv3, YOLOv4 and YOLOv5 for Autonomous Landing Spot Detection in Faulty UAVs", *Sensors 2022*, 22(2), 464.

Sarkale, A., Shah, K., Chaudhary, A., Nagarhalli, T. (2018). "An Innovative Machine Learning Approach for Object Detection and Recognition", *2018 Second International Conference on Inventive Communication and Computational Technologies* Coimbatore, Hindistan, 20-21 Nisan 2018.

Sochor, J., Juránek, R., Špaňhel, J., Maršík, L., Široký, A., Herout, A. (2019). "Comprehensive Data Set for Automatic Single Camera Visual Speed Measurement", *IEEE Transactions on Intelligent Transportation Systems*, 20(5), 1633 – 1643.

Tan, M., Pang, P., Le, Q. V. (2019). "EfficientDet: Scalable and Efficient Object Detection", 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR),* Seattle, WA, A.B.D., 13-19 Haziran 2020.

Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., Liu, C. (2018). "A survey on deep transfer learning", *27th International Conference on Artificial Neural Networks (ICANN 2018),* Rhodes, Yunanistan, 4-7 Ekim 2018.

Zhao, R., Wang, X. (2013). "Counting vehicles from semantic regions", *IEEE Trans. Intell. Transp. Syst.*, 14(2), 1016-1022.