



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



SENSÖR BİRLEŞTİRME TEKNİKLERİ
KULLANILARAK OTONOM ROBOTİK BİR
SİSTEMİN GELİŞTİRİLMESİ

Berat YILDIZ

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Haziran-2019
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Berat YILDIZ tarafından hazırlanan "Sensör Birleştirme Teknikleri Kullanılarak Otonom Robotik Bir Sistemin Geliştirilmesi" adlı tez çalışması 26/06/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Cemil SUNGUR

Danışman

Dr. Öğr. Üyesi Akif DURDU

Üye

Dr. Öğr. Üyesi Ahmet KAYABAŞI

İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Yakup KARA
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Berat YILDIZ

Tarih: 27.06.2018

ÖZET

YÜKSEK LİSANS TEZİ

SENSÖR BİRLEŞTİRME TEKNİKLERİ KULLANILARAK OTONOM ROBOTİK BİR SİSTEMİN GELİŞTİRİLMESİ

Berat YILDIZ

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Akif DURDU

2019, 61 Sayfa

Jüri

**Dr. Öğr. Üyesi Akif DURDU
Prof. Dr. Cemil SUNGUR
Dr. Öğr. Üyesi Ahmet KAYABAŞI**

Otonom robotların çalışma prensibi temel olarak, ortamda bulunan sensörlerden elde edilen verilerin robotlar tarafından işlenip anlamlandırılması ve anlamlandırılan bu verilere karşı tepki oluşturulmasına dayanmaktadır. Otonom yapıya sahip robotik sistemlerin insan, hayvan veya yük taşımacılığında kullanılan araçlara aktarılması ile otonom araçlar kavramı ortaya çıkmaktadır. Özellikle insan hayatı söz konusu olduğunda, karar verme yetisine sahip otonom sistemlerin veya araçların daha donanımlı, kararlı ve yetkin olması gerekmektedir. Dolayısıyla otonom eylemleri sağlayacak karar verme hususunda, otonom araçlarda kullanılacak olan sensörlerin nitelikleri çok önemlidir. Öte yandan, sensörlerin birbirlerine göre avantaj veya dezavantaja sahip olmaları onların birlikte kullanımını gerekli kılmaktadır. Birden fazla sensörün sağladığı veriler birleştirilerek kullanıldığında daha olumlu sonuçlar verebilmektedir.

Yapılan tez çalışmasında, araştırmalar sonucunda elde edilen bilgiler ışığında sensör birleştirme uygulamasının yapılabilmesi için yeni bir yöntem üzerinde çalışılmıştır. Yapılan uygulamalarda daha önce Massachusetts Teknoloji Enstitüsü (MTE) Otonom Yarış Aracı (OYT) projesi temel alınarak OpenZeka firmasının düzenlediği yarışmalarda kullanılan Otonom Araç Geliştirme Kiti'nden faydalanılmıştır. Araç üzerinde bulunan kamera ve lazerli görüntüleme algılama ve mesafe (LIDAR) sensör verileri arasında sensör birleştirme işlemi gerçekleştirilmiştir. Robotik-Otomasyon ve Kontrol Laboratuvarı (RAKLAB) bünyesinde araç kiti için bir parkur oluşturulmuştur. Bu parkurda, otonom araç kiti üzerinde bulunan kamera ve LIDAR sensörlerinden alınan verilerin birleştirmesinden önceki parkurda sergilediği performans ile birleştirildikten sonraki performansları değerlendirilmiş ve otonom sürüş sistemine olan katkısı irdelenmiştir. Öncelikle, parkurdan alınan kamera görüntüleri Derin Öğrenme (DÖ) algoritmalarından biri olan Konvolüsyonel Sinir Ağları (KSA) modelinde eğitilmiştir. Sonrasında, LIDAR sensöründen elde edilen nokta bulutundaki veriler gri seviyeli piksel değerlerini içeren görüntülere çevrilmiş ve eğitilmiştir. Son olarak, kamera ve LIDAR görüntüleri KSA ağ modelinin Tam Bağlı Katmanlarında (TBK) birleştirilerek eğitilmiştir. Yapılan birleştirme işlemi sonrasında elde edilen eğitim sonuçları kurulan parkurda gerçek zamanlı olarak otonom araç kiti ile denemiştir. Tek başına kameradan ve tek başına LIDAR sensöründen kaynaklanan hatalar en aza indirilmiştir.

Anahtar Kelimeler: Derin Öğrenme (DÖ), Engelden Kaçınma, Lazerli Görüntüleme Algılama ve Mesafe Sensörü (LIDAR), Otonom Robotik Sistemler, Sensör Birleştirme.

ABSTRACT

MS THESIS

DEVELOPMENT OF AN AUTONOMOUS ROBOTIC SYSTEMS USING SENSOR FUSION TECHNIQUES

Berat YILDIZ

**Konya Technical University
Institute of Graduate Studies
Department of Electrical-Electronics Engineering**

Advisor: Asst. Prof. Dr. Akif DURDU

2019, 61 Pages

**Jury
Asst. Prof. Akif DURDU
Prof. Dr. Cemil SUNGUR
Asst. Prof. Ahmet KAYABAŞI**

The principle of the autonomous robots is based on the fact that the data obtained from the sensors in the environment is processed and interpreted by the robots and the response to these meaningful data is generated. The concept of autonomous vehicles emerges with the transfer of autonomous robotic systems to the vehicles used in human, animal or freight transportation. Especially when it comes to human life, autonomous systems or instruments with the ability to make decisions need to be better equipped, stable and competent. Therefore, the qualifications of the sensors to be used in autonomous vehicles are very important in making the decision to provide autonomous actions. On the other hand, the fact that the sensors have advantages or disadvantages compared to each other makes it necessary to use them together. The data provided by more than one sensor can be combined with more positive results. In the thesis study, a new method has been studied in order to perform the sensor integration application in the light of the information obtained as a result of the research. The Autonomous Vehicle Development Kit, which was used in the competitions organized by OpenZeka company, was used on the basis of MEC Autonomous Racing Vehicle (RACECAR) project. Sensor integration between the camera and Laser Image Detection and Ranging (LIDAR) sensor data on the vehicle has been performed. A track has been created for the vehicle kit within the Robotics-Automation and Control Laboratory (RACLAB). In this course, the performances of the camera on the autonomous car kit and the data received from the LIDAR sensors before being combined with the performance they performed on the track were evaluated and their contribution to the autonomous driving system was evaluated. First of all, camera images taken from the course were trained in Convolutional Neural Networks (CNN) model which is one of the Deep Learning (DL) algorithms. The data in the point cloud obtained from the LIDAR sensor were then translated and trained into images containing gray level pixel values. Finally, the camera and LIDAR images have been trained by combining the Fully Connected Layers (FCL) of the CNN network model. The training results obtained after the joining process were tested in real time with the autonomous tool kit in the established track. Errors caused by the camera alone and the LIDAR sensor alone are minimized.

Keywords: Deep Learning (DL), Obstacle Avoidance, Laser Image Detection and Ranging (LIDAR), Autonomous Robotic Systems, Sensor Fusion.

ÖNSÖZ

Tez çalışmam sırasında ve hayatımın her anında, yardımlarını ve anlayışını esirgemeyerek bana sabırla destek veren ve bu günlere gelmemi borçlu olduğum aileme, tüm meslektaşlarıma ve arkadaşlarıma teşekkürlerimi sunarım.

Bu tez çalışmama katkıda bulunan danışmanım Sayın Dr. Öğr. Üyesi Akif DURDU'ya teşekkürlerimi sunuyorum.

Berat YILDIZ
KONYA-2019



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM.....	13
3.1. Otonom Robotik Sistemler	13
3.1.1. Otonom Araçlar	15
3.1.2. Otonom Araç Kiti	18
3.2. Makine Öğrenmesi.....	20
3.2.1. Derin Öğrenme (DÖ)	22
3.3. Robot İşletim Sistemi (ROS)	27
4. UYGULAMA VE SONUÇLAR	29
4.1. Veri Seti Oluşturma	29
4.1.1. LIDAR nokta uzayından görüntü elde edilmesi	31
4.1.2. Veri Seti Çoğaltma.....	33
4.2. KSA Algoritması ile Eğitim ve Test İşlemleri.....	34
4.2.1. Kamera Görüntülerinin Eğitimi ve Testi	35
4.2.2. LIDAR Verilerinden Elde Edilen Görüntülerinin Eğitimi ve Testi.....	39
4.2.3. Sensör Birleştirmesi ile Elde Edilen Verilerin Eğitimi ve Testi	40
4.3. Eğitim ve Test Sonuçları.....	42
5. SONUÇLAR VE ÖNERİLER	46
5.1 Sonuçlar	46
5.2 Öneriler	47
KAYNAKLAR	49
ÖZGEÇMİŞ	53

SİMGELER VE KISALTMALAR

Simgeler

x_m	: Giriş değişkeni
w_{km}	: Ağırlık değerleri
$\varphi(\cdot)$: Aktivasyon fonksiyonu
$y(x)$: Çıkış değeri
k	: İterasyon sırası
$GSP(x)$: Gri seviyeli piksel değeri
X	: Engelin ile LIDAR arasındaki mesafe
y_i	: Gerçek teker açısı
\tilde{y}_i	: Tahmin edilen teker açısı

Kısaltmalar

İHA	: İnsansız Hava Araçları
İSAA	: İnsansız Sualtı Araçları
SKA	: Sürücüsüz Kara Araçları
ABD	: Amerika Birleşik Devletleri
MTE	: Massachusetts Teknoloji Enstitüsü
OYT	: Otonom Yarış Aracı
LIDAR	: Lazerli Görüntüleme Algılama ve Mesafe
DÖ	: Derin Öğrenme
ELH	: Eşzamanlı Lokalizasyon ve Haritalama
KSA	: Konvolüsyonel Sinir Ağları
DSA	: Derin Sinir Ağı
KF	: Kalman Filtresi
DVM	: Destek Vektör Makinesi
SBKB	: Sadece Bir Kere Bakma
GPS	: Küresel Konumlama Sistemi
IMU	: Atalet Ölçüm Birimi
TÖ	: Takviyeli Öğrenme
YEYN	: Yinelemeli En Yakın Nokta
BMSDUA	: Bulanık Mantık Sistemine Dayalı Uyarlanıç Ağ
RACLAB	: Robotik-Otomasyon ve Kontrol Laboratuvarı
ROS	: Robot İşletim Sistemi
GPU	: Grafik İşlemci Birimini
TSA	: Tekrarlayan Sinir Ağları
TBK	: Tam Bağlı Katmanına

1. GİRİŞ

Robotik sistemler, elektrikli ve mekanik sistemlerden oluşturulmuş bu sistemler ile algılama ve kontrol işlevlerini gerçekleştirebilen, bilgisayar programlamalarına bağlı olarak otonom veya önceden belirlenen görevleri yerine getiren sistemlerdir. Robotik sistemler sağlıktan askeri uygulamalara, endüstriden kişisel hizmetlere kadar birçok alanda faaliyet göstermekte ve gün geçtikçe kullanıldığı faaliyet alanları da genişlemektedir. Geçmişten günümüze birçok alanda, önceden programlanmış robotlar kullanılmaktadır. Bunlar önceden programlanmış ve yazılımlarında bulunan çalışma prensibine göre faaliyet gösteren robotlardır. Bu robotlar, herhangi bir sinyal verisini işlemeye gerek duymadan fonksiyonlarını gerçekleştirebilen mekanizmalardır. Aldıkları komutlar doğrultusunda belirlenen spesifik görevleri yerine getirebilmektedir. Dolayısıyla karar verme mekanizmasına sahip değildir ve çok kompleks işlemler dışında birçok alanda kullanılmaktadırlar. Yaygın bir kullanım alanına sahip olan önceden programlanmış robotlar artık yerini yavaş yavaş otonom robotlara bırakmaktadır.

Otonom robotlar, çevresinden sensörler aracılığıyla bilgiler almaktadır. Alınan bu bilgileri mikroişlemciler veya mikrodenetleyiciler gibi karar mekanizmalarına aktarabilen ve burada anlamlandırıp bir sonuç üreterek belirli tepkiler verebilen otonom robotlar üretilmektedir. Bu robotlar, ses, ışık, basınç, sıcaklık vb. faktörlere duyarlı sensörlerle ve bunlara karşı tepkiler verebilecek mekanizmalarla donatılmıştır (Asama ve ark., 2013).

Teknolojik gelişmelerin hızla ilerleme kaydettiği son dönemlerde özellikle insan, hayvan veya yük taşımacılığında kullanılan araçların otonom hale getirilmesi için çeşitli çalışmalar yürütülmektedir. Bu tür çalışmaların başında İnsansız Hava Araçları (İHA), İnsansız Sualtı Araçları (İSAA), Sürücüsüz Kara Araçları (SKA) ve deniz taşımacılığında kullanılan yük gemileri gibi çeşitli araçlar gelmektedir. Bu araçlar üzerinde yapılan çalışmalar hızla ilerlemekte ve otonom sistemler üzerinde önemli gelişmeler kaydedilmektedir. Bu gelişmelerin güvenli ve etkili sonuçlar verebilmesi için oldukça hassas fonksiyonlara sahip sistemler olması gerekmektedir. Nitekim, Amerika Birleşik Devletleri'nin Arizona eyaletinde, sürücüsüz bir otomobil ilk kez bir yayanın ölümüne yol açmış ve aracın karıştığı kazanın ardından şirket tüm sürücüsüz araç testlerini durdurduğunu açıklamıştır (BBC, 2018). Bu durumdan da anlaşılacağı üzere otonom araç teknolojisinde oldukça hassas ve güvenilir uygulamaların geliştirilmesi

önem arz etmektedir. Bu araçların çevre ile olan etkileşimi donanımlarında bulunan gelişmiş sensörlerle sağlandığından, sensörlerin işlevlerini tam olarak yerine getirmesi gerekmektedir. Herhangi bir sensörde meydana gelecek herhangi bir aksaklık, sebebi ne olursa olsun telafi edilebilir ve diğer sensörler tarafından giderilebilir olmalıdır.

Yapılan bu tez çalışmasında, yukarıdaki durumlar göz önünde bulundurularak hali hazırda gelişmekte olan ve daha verimli bir şekilde nesne algılama, yer tespiti ve engelden kaçınma konusunda tam olarak yeterlilik sağlamamış, geliştirilmeye açık olan otonom robot uygulamaları gerçekleştirmek için konuyla ilgili çalışmalar incelenmiş ve kullanılan yöntemler araştırılmıştır. Yapılan inceleme ve araştırmalar sonucunda daha verimli bir otonom sürüş deneyimi için robotik aksam üzerinde bulunan sensörlerle 'Sensör Birleştirme' uygulaması yapılmaya çalışılmıştır. Yapılan sensör birleştirme uygulaması ile sensörler arasında tamamlayıcı (birlikte kullanımında daha iyi sonuçlar verebilecek) ve birbiri yerine kullanılacak bir veri birleşimi sağlanması hedeflenmiştir. Arızalan sensör veya yaşanan aksaklıklar durumunda yapılan veri birleştirme (füzyonu) sayesinde bir sensör diğer bir sensörün hatalı çalışmasından veya çalışmamasından kaynaklanan hatayı azaltabilecek veya ortadan kaldıracaktır. Ayrıca veri birleşiminin sağlandığı uygulamalar sensörlerin ayrı ayrı yapacağı uygulamalardan daha iyi sonuçlar verebilmektedir. Özellikle ortam koşullarına karşı hassas olan sensörlerin bir arada kullanılması hataların azalmasına önemli ölçüde katkıda bulunmaktadır.

Bu amaçla tez uygulaması olarak yapılan çalışmada daha önce Massachusetts Teknoloji Enstitüsü (MTE) Otonom Yarış Aracı (OYT) projesi temel alınarak OpenZeka firmasının düzenlediği yarışmalarda kullanılan Otonom Araç Geliştirme Kiti'nden faydalanılmıştır. Otonom sistemlerde daha verimli bir şekilde nesne algılama, yer tespiti ve engelden kaçınma uygulamalarının gerçekleştirilebilmesi için robotik geliştirme kiti aksamı üzerinde bulunan sensörler ile sensör birleştirme uygulaması yapılmıştır. Buradaki temel hedef, aracın üzerinde bulunan sensörden alınan verileri birlikte işleyerek daha verimli bir şekilde bulunduğu ortama adapte olmasını sağlamaktır. Aynı anda birçok sensörden alınan verilerin birlikte işlenebilmesi için sensör birleştirme ya da diğer bir adıyla sensör füzyonu yapılmaya çalışılmıştır.

Özellikle otonom araçlarda ortam şartları çevresel faktörlere bağlı olarak sık sık değişebilmekte ve bu değişikliklerden kaynaklı sensör hataları veya arızalanmalar olmaktadır. Birleştirilmiş sensör verileri sayesinde birbirini tamamlayan sensörlerden birinde meydana gelebilecek aksaklıklar diğer sensör tarafından giderilebilecektir. Bu

sayede otonom sürüş esnasında herhangi bir sensör devre dışı kaldığında diğer sensör yardımıyla güvenli sürüşe devam edilebilecektir.

Uygulama sırasında kullanılacak olan araç kiti belirli kriterle sahip bir platformda otonom sürüş denemelerini gerçekleştirmiştir. Otonom sistemlerde genellikle ultrasonik, kızılötesi, kamera veya lazerli görüntüleme algılama ve mesafe sensörü (LIDAR) gibi sensörler kullanılmaktadır. Bu çalışmada, kamera ve LIDAR sensörleri kullanılmış ve robotun etrafındaki değişiklikleri algılayarak otonom bir şekilde sürüş yapması sağlanmıştır. Bu sürüş sırasında sensörlerden alınan veriler göz önünde bulundurularak belirli sensörler üzerinde veri birleşimi yapılmaya çalışılmıştır.

Araçta bulunan kamera ile alınan görüntüler, birçok alanda kullanılan ve Yapay Zeka (YZ) metotlarından biri olan Derin Öğrenme (DÖ) yöntemiyle değerlendirilmiş ve ortamda bulunan engellerin veya nesnelerin tespiti yapılabilmektedir. Tespit edilen bu nesnelerin otonom araca olan uzaklıkları LIDAR sensörü ile ölçülmüştür. Aracın ön kısmına monte edilen bu LIDAR sensörü kullanılarak elde edilen engellerin bulunduğu mesafe aralıkları gri seviye (grayscale) görüntülere çevrilmiştir. Kamera kullanılarak elde edilen görüntüler ile LIDAR verilerinden oluşturulan görüntülerin DÖ katmanlarında birleştirilmesi ile aracın otonom sürüş yeteneğinin en üst seviyeye çıkartılması sağlanmıştır. Bahsedilen bu uygulamaların hem simülasyon hem de gerçek zamanlı olarak robot üzerinde yapılması ve sonuçlarının göz önünde bulundurularak otonom araçlar için örnek teşkil etmesi istenmektedir.

Bu tez çalışmasında önerilen yöntemler otonom araç kiti üzerinde başarılı bir şekilde uygulanmış ve elde edilen sonuçlar paylaşılmıştır. Bundan sonra yapılacak çalışmalara temel oluşturacak bu tez çalışması, Türkiye'deki otonom robot sistemlerinin gelişimine katkı sağlayabilecektir.

2. KAYNAK ARAŞTIRMASI

Otonom robotik sistemlere olan ilginin artması sonucunda meydana gelen hızlı gelişmeler ile beraber otonom sistem teknolojisi, askeri savunma sistemlerinde, insansız hava ve kara araçlarında, yük ve yolcu taşımacılığında kullanılan deniz araçlarında, insan hayatını kolaylaştırmak, can ve mal güvenliğini sağlamak ve çeşitli alanlarda hizmet veren işletmelerde daha etkin ve verimli çalışmaların yapılabilmesi için tercih edilebilir düzeylere ulaşmıştır. Bu otonom sistemler geliştirilirken karşılaşılan problemler doğrultusunda birçok alanda farklı çalışmalar yapılmıştır. Eşzamanlı lokalizasyon ve haritalama (ELH), navigasyon, nesne algılama, engel tanıma, engelden kaçınma gibi başlıca konularda çok çeşitli çalışmalarda bulunulmuştur (Yavuz ve ark., 2006; Yoon ve ark., 2009; Trepagnier ve ark., 2011; Zhu ve ark., 2012). Bu çalışmalar kapsamında yapılan uygulamalar gözlemlendiğinde sensörlerin avantaj ve dezavantaj durumlarına göre hata olasılıklarının hala devam etmesi, sensörler üzerinde de yenilikçi yaklaşımlar denenmesine yol açmıştır. Uygulamalar kapsamında kullanılan sensörler dikkate alındığında sensör birleştirme kavramı ise son dönemlerde önemli bir çalışma konusu haline gelmeye başlamıştır. Gelişen yeni teknolojilerle birlikte sensör çeşitliliğinin artması, özellikle otonom sistemlerde sensörlere düşen görevi önemli ölçüde arttırmaktadır. Bu çalışma kapsamında, literatürde bulunan otonom robotik sistemler için kullanılan ve geliştirilen yöntemler incelenmiştir. Ayrıca, bu yöntemlerin otonom araçlarda kullanılan sensörler arasında yapılan sensör birleştirme için geliştirilebilecek yönleri irdelenmiştir.

Otonom sistemlerde çevrede bulunan nesnelere ve engellerin algılanması veya tespit edilmesi sistem karar mekanizması için gerekli olan bir etmendir. Robot tarafından yapılacak olan otonom hareket, ortamda bulunan nesnelere veya engellerin varlığına bağlıdır. Dolayısıyla otonom robotik sistemlerde algılanan nesnenin durumuna göre hareket mekanizması kontrol edilmektedir. Nesne algılama ve engel tespiti işlemleri için de makine öğrenmesi veya görüntü işleme gibi yöntemler sıklıkla kullanılmaktadır. Bu tez kapsamında da literatürde bulunan nesne algılama ve engel tespiti yöntemleri ile alakalı çalışmalar incelenmiştir. Sensör birleştirme yöntemlerinin nesne algılanmasına ve engel tespitine olan katkısı irdelenmiştir.

Video görüntülerinden yola çıkılarak nesne algılama işleminin yapıldığı çalışmalarda alınan görüntülerin arka planının çıkarılması ile nesnelerin tespit edilebildiği algoritmalar geliştirilmiştir.

Karasulu ve Korukoglu (2012) tarafından yapılan çalışmada, YZ çalışmalarında bir optimizasyon tekniği olan benzetilmiş tavlama (simulated annealing) kullanılarak videolardaki nesnelerin algılanması için kullanılan arka plan çıkarma yöntemi geliştirilmiştir. Böylece video görüntülerinden etkin bir şekilde nesne tespiti yapılabilmektedir.

Yu ve ark. (2010) yapılan çalışmada, gelişmiş parçacık sürü optimizasyonu algoritması kullanılarak görüntüdeki nesneler hızlı bir şekilde tespit edilebilmiştir. Ayrıca görüntülerdeki nesnelerin çok hızlı hareket ettikleri durumlarda bile nesnelerin tespit edilebildiği gözlemlenmiştir.

Liu ve ark. (2012) çalışmalarında sinir ağları ve Kalman Filtresi (KF) kullanarak hareketli kameralardan alınan görüntülerden nesnelerin hareketini tespit etmişlerdir. Elde ettikleri sistemi futbol robotunda denemiş ve düşük hata oranıyla iyi bir performans sergileyebilmişlerdir.

Trafikteki akışı takip edebilmek ve görüntüler içerisinde üst üste gelen nesnelere ayırabilmek için kendi kendini düzenleyebilen bir sinir ağı modeli tasarlanmıştır. Bu yapı sayesinde nesnelerin karmaşık olduğu görüntülerde nesnelerin ayırt edilebilmesinin kolaylaştırılacağı öne sürülmüştür (Luque-Baena ve ark., 2013).

Nesne algılama çalışmaları, otonom araçlar içinde oldukça önemli bir konudur. Görüntülerin sınıflandırılması ve nesne algılama gibi konularda ön plana çıkan ve son zamanlarda da popüleritesi artan ağ yapılarından biri de DÖ ağ yapılarıdır. Derin Sinir Ağı (DSA) kullanılarak nesnelerin tensör (geometrik olarak ifade edilmiş vektör) özellikleri ile Ölçek Değişmez Özellik Dönüşümü (Scale-invariant feature transform) algoritması kombine edilerek video görüntüleri üzerinde nesne sınıflandırılması yapılmıştır. Simülasyonlar ile sistem üzerinde uygulamalar yapılarak nesne sınıflandırılmasının doğruluğu test edilmiştir (Najva ve Bijoy, 2016). DÖ ağ yapılarından bir diğeri olan Konvolüsyonel Sinir Ağları (KSA) kullanılarak kameradan elde edilen görüntülerden yaya tespit sistemi geliştirilmiştir. Geliştirilen bu sistem NVIDIA kartları üzerinde uygulanmış ve yaya tespitinde kullanılmıştır (Tomè ve ark., 2016).

Otonom araçların stop (fren) lambalarının algılanması ile ilgili yapılan bir çalışmada, gerçek zamanlı tek bir görüntüden iki aşamada fren lambası tanıma sistemi

geliştirilmiştir. Öncelikle öndeki araçların arka tarafından alınan görüntü ve LIDAR verileri Fren Lambaları Modelleri adlı geniş bir veri tabanı kullanılarak çok katmanlı bir sinir ağında eğitilmiştir. Eğitim sonucunda elde edilen görüntüler fren görüntüleri ve normal görüntüler olarak sınıflandırılmıştır. Sonraki aşamada ise fren lambalarının tespitinin doğruluğunu arttırmak ve hızlandırmak için yol bölümlendirmesi ve ilgi bölgesi (Region of interest) belirleme yöntemi geliştirilmiştir. Gerçek video üzerinden alınan sonuçlarla birlikte arkadan çarpmaya bağlı kazaların önlenebileceği öne sürülmüştür (Wang ve ark., 2016).

Yine araç stop lambalarının tespiti için Vancea ve ark. (2017) tarafından yapılan bir diğer çalışmada öncelikle görüntüler içerisinde araçlar tespit edilmiş, daha sonra bu araçların fren lambaları tespit edilmeye çalışılmıştır. İlk olarak belirli bir eşik değeri belirlenerek kırmızı renkli bölgeler görüntülerde tespit edilmiştir. DÖ ağlarında yapılan eğitimlerle de bu bölgelerdeki fren lambaları tespit edilmeye çalışılmıştır. Tespiti yapılan lambaların doğruluğunu kesinleştirmek için boy ve merkezi yükseklikleri karşılaştırılmıştır. Lamba çiftlerinin uyumluluğu için histogram üzerinde karşılaştırmalar yapılmış ve KF kullanılarak da hatalı piksel değerleri filtrelenmiştir.

Otonom sistemlerde nesne algılama konusunda yapılan çalışmalarda daha verimli sonuçlar alınması için bu çalışmalarda kullanılan sensörlerde sensör birleştirme yoluna gidilen uygulamalarda bulunmaktadır. Garcia ve ark. (2017) tarafından yapılan çalışmada, şehirler arası yollarda güvenli sürüşlerin gerçekleştirilebilmesi için sensörler arasında veri birleştirilmesi yapılmaya çalışılmıştır. Farklı koordinatlarda bulunan kamera ve lazer sensör verileri dinamik (on-line) kalibrasyon çözümü kullanılarak aynı koordinatlara indirgenmiştir. Sistem verileri Global En Yakın Komşular (Global Nearest Neighbor) ve Kokusuz Kalman Filtresi (Unscented Kalman Filter) baz alınarak denenmiştir. Ayrıca Ortak Olasılıklı Veri Birliği (Joint Probabilistic Data Association) algoritmasını geliştirerek bu çalışmanın gerçek zamanlı olarak çalışabilen ve güvenilir bir sistem olduğu öne sürülmüştür. Çalışma kapsamında yapılan testlerde sensör birleştirme yöntemi ile %92 başarı elde edilebilmiştir.

Suhr ve Jung (2018) tarafından otomatik park sistemlerinde çevrede bulunan engellerin lokalizasyonun yapılabilmesi için sensör birleştirmesine dayalı bir çalışma yapılmıştır. Önerilen bu yöntemde kameradan alınan görüntüler, ultrasonik sensörden gelen mesafe aralıkları, teker hız sensöründen gelen veriler ve taşıt odometrisi birleştirilmiştir. Öncelikle aracın odometri ve ultrasonik sensör verileri kullanılarak engelin konumu yüzeysel bir şekilde tespit edilmiştir. Daha sonra bu engelin konumuna

bağlı olarak alınan görüntülerden engelin dikey ana hatları tespit edilmiştir. Bu hatlar odometri verisine bakılarak birleştirilmiştir. Son olarak da Rasgele Örnek Konsensüsü kullanılarak birleştirilen ana hatların kesişme noktası hesaplanarak engelin kesin lokasyonu tespit edilmeye çalışılmıştır. Önerilen çalışma üzerinde 14 farklı park durumu denenmiştir. Bu denemeler sonucunda yuvarlak ve kavisli engellerde hatalı sonuçlar gözlemlenmiştir.

Otonom araçlardaki önemli etmenlerden olan çarpışmadan kaçınma üzerinde çalışan Wei ve ark. (2018) tarafından LIDAR ve kamera üzerinden yapılan sensör birleştirme uygulaması ile çarpışma önleyici bir sistem geliştirilmiştir. Yapılan uygulamada LIDAR verilerinden oluşan nokta bulutundaki tüm veriler Destek Vektör Makinesi (DVM) kullanılarak eğitilmiş, duba ve duba dışındaki nesnelere olarak iki grupta sınıflandırma yapılmıştır. DVM sonucunda alınan veriler Hiper-parametre optimizasyon algoritması ve sigmoid fonksiyonu kullanılarak 0 ile 1 arasında sözde güven (pseudo-confidence) puanları elde edilmiştir. Kamera görüntülerinden oluşan veri seti ise DÖ modellerinden olan Sadece Bir Kere Bakma (SBKB) yöntemiyle eğitilmiş ve tespit edilen nesnelere güven (confidence) puanları 0 ile 1 arasında kaydedilmiştir. Son olarak elde edilen puanlar Bulanık Mantık kullanılarak birleştirilmiştir. Gerçek zamanlı yapılan denemeler sonucunda, Kamera ve LIDAR veri birleşiminden oluşan sistemin engel tespitinde daha başarılı olduğu öne sürülmüştür.

Deniz araçları için yapılan bir çalışmada otonom sistemin niteliğini arttırmak için Avrupa Gemi Simülasyonu'ndan elde edilen veriler üzerinde DÖ modellerinden AlexNet kullanılarak çarpışma durumlarından kurtulabilecek bir sistem geliştirilmeye çalışılmıştır. Yapılan eğitim ve test sonuçlarına göre gemi kontrolü engellere çarpmadan sağlanabilecektir. Ayrıca bu çalışmanın, gemilerde otomatik navigasyon sistemleri açısından bir ön çalışma niteliğine sahip olduğu öne sürülmüştür (Xu ve ark., 2018).

Gemiler dışında su altı araçları için yapılan bir çalışmada da basit bir yapıya sahip olan moleküler bir kamera kullanılarak alınan görüntüler, DÖ yapısı kullanılarak iletim haritası oluşturulmaya çalışılmıştır. Oluşan harita görüntünün parçalarına bakarak engel tahmininde bulunmuştur. Sonrasında da bu haritada en uygun kaçış yönü bulunabilmektedir. Alınan sonuçlara göre sualtı araçlarının mercan resiflerinden, balıklardan, deniz tabanından ve kamera görüntüsünde yer alan diğer nesnelere kaçabileceği öne sürülmüştür (Gaya ve ark., 2016).

Nesne tespiti konusunda zorlu çalışma alanlarından biri de hareketli nesnenin tespiti ve takibidir. Otonom araç sistemlerinde meydana gelebilecek ani durumlarda, çevredeki nesnelerin hareketinin algılanması da önemli bir durumdur.

Chavez-Garcia ve Aycard (2016) tarafından yapılan çalışmada, Radar, LIDAR ve kamera sensörleri kullanılarak trafikteki nesnelerin tespiti, sınıflandırılması ve takibi üzerinde çalışılmıştır. Radar ve LIDAR ile elde edilen uzaklık verileri ile iki boyutlu Bayesian yerleşim haritası oluşturulmuştur. Bu haritada bulunan hücreler, içerisinde nesne (yaya, bisiklet, taksi veya kamyon) olup olmaması durumuna göre belirli ölçümler ile ilişkilendirilmiştir. Haritada bulunan araçların yeri maksimum olasılık yaklaşımı ile tespit edilmiştir. Bu hücreler içerisinde daha önceden nesne varken, daha sonra boş görünüyorsa nesnenin hareketli olduğu düşünülmüştür. Kamera verilerinden nesne tespitinde bulunabilmek için Seyrek Yönlendirilmiş Gradyanların Histogramları yöntemi ile görüntülerin özellikleri çıkartılmıştır. Çıkarılan özellikler ile sınıflandırma yapmak için de LIDAR verilerinden elde edilen nesnelere ilgili alanlar üzerinde Ayrık AdaBoost adlı, güçlendirmeye dayalı bir öğrenme algoritması uygulanmıştır. Gerçek zamanlı araçlar üzerinde yapılan testlerde nesnelerin tespitinde, sınıflandırılmasında ve takibinde verimli sonuçlar alınmıştır.

Nesne takibi ve çarpışmadan kaçınmak adına Dieterle ve ark. (2017) tarafından yapılan bir çalışmada, mobil platform üzerinde sabit bir stereo kamera ve LIDAR kullanılarak yapılan sensör veri birleştirilmesi ile dinamik nesne takibi yapan bir sistem sunulmuştur. Sistem çalışma prensibi LIDAR verilerinden oluşan üç boyutlu nokta bulutundan nesnelerin algılanması, ardından hiyerarşik veri birleştirme yöntemine bağlı Ortak Olasılıklı Veri Birliği Filtresi kullanılarak yapılan nesne takibine dayanmaktadır. Kullanılan hiyerarşik veri birleştirme yönteminde, nesne tespitinde daha iyi sonuçlar veren LIDAR sensörüne öncelik verilmiştir. Kameranın geniş görüş alanından alınan veriler ile de LIDAR da meydana gelen geçici aksamalar giderilebilmektedir.

Sensör birleştirmenin temel alındığı bir başka çalışmada da gerçek zamanlı araç takibi yapılmak istenmiştir. Akıllı telefonların özelliklerinden faydalanarak araçtaki manevraları takip edebilen, aracın konumu hakkında bilgi sağlayan ve hata tahmininde bulunabilen bir sistem tasarımı üzerinde çalışılmıştır. Bu çalışmada bulunan sistem İvmeölçer, Jiroskop ve Küresel Konumlama Sistemi (GPS) sensörlerinin verilerinin birleştirilmesi ile oluşturulmaktadır. Veri birleştirmesinde üstel hareketli ortalama filtresi, alçak geçiş filtresi ve KF kullanılmıştır. Yapılan çalışmanın genel itibarıyla gerçek zamanlı uygulamalarda lokalizasyon ve takip sistemi açısından uygulanabilir bir

performansa sahip olduđu öne sürülmüştür (Plangi ve ark., 2018). Yine benzer bir sensör birleştirme konusunda Bostanci ve ark. (2018) tarafından yapılan çalışmada, dış ortamlarda yapılan takip sistemlerinin geliştirilmesi için Bulanık Uyarlamalı Çoklu Modeller baz alınarak geliştirilen birleştirme uygulaması kullanılarak Kamera, Atalet Ölçüm Birimi (IMU) ve GPS sensörleri arasında sensör birleştirme uygulaması yapılmıştır. Bu çalışmada alınan sonuçlar, bulanık hareket modellerinden ve bir kamera sensöründen elde edilen ek tahminler nedeniyle geliştirilen izleme sisteminin geleneksel bir GPS-IMU birleştirmeye yaklaşımdan daha doğru olduğunu göstermektedir. Yapılan çalışma ile kamera-GPS-IMU birleştirmesinin sıradan GPS-IMU birleştirmesine nazaran daha doğru sonuçlar verebildiği öne sürülmektedir.

Otonom robotik sistemlerde yapılan çalışmalardaki önemli konulardan bir diğeri de navigasyon, haritalama ve lokalizasyon çalışmalarıdır. Robotların açık alanlarda kullanımı sırasında eğer geniş alanda çalışmalar yapılacaksa robotun konumunun bilinmesi veya robotun bulunduğu çevrenin haritasının robot tarafından çıkartılabilmesi robotun otonom davranışlarına önemli ölçüde katkı sağlayacaktır. Otonom hareketi sağlayacak robotun bulunduğu ortam bilgisine sahip olması, gerçekleştireceği fonksiyonlar için kullanacağı en doğru ve en kısa rotanın tanımlanması çeşitli navigasyon, haritalama ve lokalizasyon yöntemleri ile sağlanabilmektedir. Daha önce yapılan çalışmalar kapsamında, aracın veya engelin lokalizasyonunun haritalama ve navigasyon ile belirlenmesi ile alakalı çalışmalar incelenmiş, sensör birleştirmesi ile bu alandaki ilerlemeler irdelenmiştir.

Particke ve ark. (2017) tarafından yapılan mobil platformlar üzerinde gerçek zamanlı nesne tespiti ve lokalizasyonu çalışmasında üç boyutlu bir kameradan alınan görüntü ve derinlik verileri birleştirilip SBKB-v2 ağ yapısı kullanılarak nesne tespiti ve lokalizasyonu yapılmaya çalışılmıştır.

İHA'lar üzerinde yapılan bir çalışmada Chen ve ark. (2017) araçların iniş lokasyonunu belirlemede yaşadığı karmaşık sorunları çözmek için daha hızlı işlem kapasitesine sahip bir KSA modeli kullanmıştır. Bu sinir ağ modeli ile iniş işaretlerini tanıma işlemi gerçekleştirildikten sonra iniş yönü ve pozisyonunu ayarlamak için de Elips Uydurma ve Shi Tomasi köşe algılama yöntemi kullanılmıştır. Yapılan testlerde %97,8 oranında doğru iniş gerçekleştirilebilmiştir. Burada, daha hızlı olan KSA modeli Elips Uydurma ve Shi Tomasi algoritmaları ile birlikte yapılan konumlandırmanın DVM, Geri Yayılımlı (Back Propagation) sinir ağı ve SBKB yöntemlerine kıyasla daha hızlı ve doğru tespitlerde bulunması üzerinde durulmuştur.

Wang ve ark. (2018) çalışmalarında çoklu görev niteliğine sahip Takviyeli Öğrenme (TÖ) kullanarak nesne lokalizasyonu gerçekleştirmeye çalışmıştır. Oluşturulan sistem eylem yürütme ve terminal olmak üzere iki bölümden oluşmakta ve ağır gizli katmanlarında birleştirilerek lokalizasyon işlemi yapılmaktadır. Alınan görüntülerden bir eylem oluşturulmuş ve bu eylemlerden terminal sinyali olarak çıkış alınmıştır. Bu sinyalin doğruluğuna göre lokalizasyon işlemi sonlandırılır. Alınan çıkış sinyali yanlış ise tekrar tekrar görüntüler incelenerek yeni sinyaller üretilmektedir. Sonuçlar üzerinde yapılan eğitimlerde az sayıda denemeyle lokalizasyon yapılabildiği öne sürülmüştür.

Rubinstein ve Erez (2016) tarafından konumlandırma ve haritalamanın birlikte yapıldığı bir çalışmada, LIDAR ve Kinetic sensörleri birlikte kullanılmış ve otonom robotun bulunduğu ortamda yol planlaması yapabilmesi ve varış noktasına doğru ilerleyebilmesi sağlanmıştır. Yinelemeli En Yakın Nokta (YEYN) ve Açgözlü Geniş Öncelikli Arama olarak adlandırılan iki yöntem kullanılarak aracın yönlendirildiği noktaya güzergahtan çıkmadan gidebilmesi sağlanmıştır. YEYN metodunun kullanıldığı bir diğer çalışmada 2 boyutlu lazer tarayıcı ve Kırmızı Yeşil Mavi-Derinlik (RGB-D) kamerası kullanılarak 3 boyutlu mobil haritalama sistemi oluşturulmuştur. Oluşturulan haritalama sistemi diğer haritalama sistemleri ile karşılaştırıldığında bu haritalama yönteminin etkin ve verimli olduğu öne sürülmüştür (Wen ve ark., 2014).

Sun ve ark. (2017), depolarda kullanılan otonom robotlar için navigasyon sistemi tasarlamaya çalışmışlardır. Depolarda bulunan ürünlerin etiketlerine doğru yapılacak hareketlerde robotların etikete en kısa ve en doğru yoldan ulaşılabilmesini sağlamaya çalışmışlardır. Öncelikle hızlı bir DÖ ağ yapısı olan KSA kullanarak raf ayakları ve etiketlerin algılanması sağlanmış, daha sonra algılanan nesnelere dünya koordinatındaki yeri Ters Perspektif Haritalama algoritması kullanılarak tespit edilmiştir. Son aşama ise olası tüm yol seçeneklerini sıralamak ve en doğru rotanın tespit edilebilmesi için denetimsiz Destek Vektör Makinası algoritması kullanılmıştır. Gerçek zamanlı olarak depolarda yaptıkları denemelerde başarılı sonuçlar almışlardır.

Navigasyon sistemi ile alakalı Bruno ve Osório (2017) tarafından yapılan bir diğer çalışmada, akıllı robotik araçların trafik işaretlerini tanıması için DÖ temelli bir görüntü sınıflandırma yöntemi uygulanmıştır. Gelişmiş Sürücü Yardımı Sistemleri, otonom araçların güvenli bir şekilde sürüş görevini gerçekleştirebilmesine yardımcı olmak için tasarlanmıştır. Bu sistemin kullanımındaki temel etken düşük çözünürlüklü görüntülerle ve aynı zamanda üst üste binmiş görüntüler üzerinde çalışabilmesidir.

Trafik ortamlarında güvenli navigasyon yapılabilmesi trafik işaret levhaları, trafik ışıkları ve trafik şeritleri aracılığıyla sağlanmaktadır. Burada, trafik sinyallerini sınıflandırmak için DÖ algoritmasının kullanılması öne sürülmüştür. Elde edilen sonuçların, popüler bir trafik işareti veri setindeki (INI-Alman Trafik İşaretleme Kıyaslaması) test doğruluğu %97,24 olarak belirtilmiştir.

Mobil robotlar için yapılan bir ELH uygulamasında robotun bilinmeyen bir ortamda sensör birleştirme algoritmaları kullanarak haritalama yapması amaçlanmıştır. Bunun için ultrasonik mesafe sensörü, optik kodlayıcı (encoder), ve IMU sensörleri kullanılmıştır. Mobil robotun tekerlek kontrolü IMU ve optik kodlayıcı birlikte kullanılarak yapılmıştır. Engel veya patinaj durumları ile karşılaşmadığı sürece optik kodlayıcı ile teker açıları belirlenmektedir. Aksi halde, IMU sensöründen gelen verilerde göz önünde bulundurulmaktadır. Jiroskop ve ivme ölçere etki eden gürültüleri azaltmak için hareketli ortalama filtre ve tamamlayıcı filtre kullanılmış, mesafe ise optik kodlayıcı kullanılarak ölçülmüştür. Robot ve engelin konum verileri Pygame kütüphanesi kullanılarak oluşturulmuştur. Yapılan uygulamalarda alınan sonuçlara göre ölçülen mesafe ve gerçek mesafe arasında 2cm'lik hata gözlemlenmiştir (Toroslu ve Doğan, 2018).

Li ve ark. (2014) tarafından LIDAR ve kamera sensörlerinin birleştirilmesi ile otonom araçlarda navigasyon sisteminin geliştirilmesi üzerine çalışma yapılmıştır. Bu çalışma kapsamında araç navigasyonunun sağlanması için sürülebilir bölge ve şerit algılama sistemi oluşturulmuştur. İlk etapta, yolun niteliği belirlenmeye çalışılmış ve yollar dar ve geniş olmak üzere iki kısma ayrılmıştır. Dar yollar için şerit algılamaya gerek olmadığından geniş yollar için şerit algılama sistemi kullanılmıştır. Bu yolların niteliği tespit edilirken kaldırım kenarları noktasal olarak tespit edilip bu noktalar birleştirilerek yolun dar veya geniş olduğu tespit edilmeye çalışılmış, yolun niteliği geniş ise şerit takibi uygulanmıştır. Şerit takibinin yapılacağı yolda kamera ve LIDAR verilerinden oluşan birleştirme algoritması sadece şerit içinde uygulanır. Dar yollarda ise Kamera ve LIDAR ile oluşturulan algoritmalar tüm yol için kullanılır. Önerilen bu yöntem ile yol yüzeyinin her bir pikselini ayırt etmek yerine aracın önündeki en uygun sürülebilir bölgeler çıkarılabilir. Yapılan testlerde bölge ve şerit algılamada %90 üzerinde başarı sağlandığı öne sürülmüştür.

Adarsh ve ark. (2018) tarafından mobil robotların navigasyon sistemi için geliştirilen bir çalışmada, Bulanık Mantık Sistemine Dayalı Uyarlanırlı Ağ (BMSDUA) kullanılarak sensör verileri üzerinde tasarlanan birleştirme algoritması sunulmuştur. Bulanık mantık ve Sinir ağlarının bir arada bulunduğu bu sistem sayesinde bu çalışmada kullanılan ultrasonik ve kızılötesi sensörlerden alınan kaynaşmış uzaklık verileri gerçek uzaklık verileri ile örtüşmektedir. Ultrasonik ve kızılötesi sensörlerden ayrı ayrı alınan ölçümlerin hata oranı BMSDUA tabanlı birleştirme algoritmasının kullanılması ile azalmıştır. Bu çalışmada, kaynaşmış verilerden alınan düşük hata oranları bu sensörlerin araç navigasyonunda daha verimli olabileceğinin bir göstergesi olarak sunulmuştur.

Yapılan literatür çalışmasında, otonom sistemler için kullanılan sensörler ve bu sensörlerin birleştirilmesi için öne sürülen yöntemler incelenmiştir. Bu incelemelerde, nesne tespiti ve engel algılamada YZ tekniklerinin önemli ölçüde etkili olduğu görülmüştür. Ayrıca bu tip problemlerin çözümünde çoğunlukla Kamera, LIDAR, ultrasonik mesafe sensörü, kızılötesi mesafe sensörü ve IMU gibi sensörler kullanılmıştır.

Bu tez kapsamında yapılan çalışmada da Kamera ve LIDAR sensörleri arasında sensör birleştirme uygulaması yapılmaya çalışılmıştır. Diğer çalışmalara nazaran bu çalışmada, sensör birleştirilmesi için kullanılan Bulanık Mantık, Kalman Filtresi ve Dönüşüm matrisleri gibi uygulamalar ile elde edilen verilerin bir dizi algoritma sonucunda birleştirilmesi yerine, sensör veri tipleri algoritmalara sunulmadan birbirine dönüştürülmüş ve birleştirme işlemi DÖ ağ modellerinde yapılmıştır. Böylece tek sensör verisiymiş gibi eğitilmiş ve sonuçlar ona göre değerlendirilmiştir. Alınan sonuçlarda sensör birleştirme yöntemi ile yapılan uygulama ile daha verimli bir otonom sürüş gerçekleştirilmiştir.

3. MATERYAL VE YÖNTEM

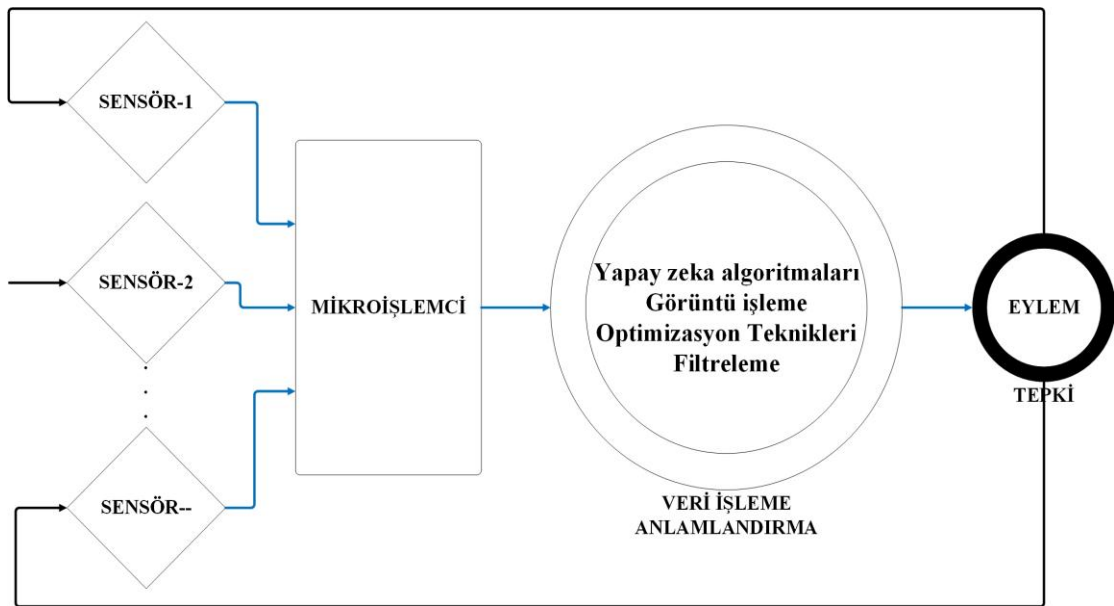
Bu tez kapsamında, hali hazırda gelişmekte olan otonom araç teknolojisinde otonom sürüşlerin daha verimli bir şekilde gerçekleştirilebilmesi için otonom araç kiti üzerine monte edilen kamera ve LIDAR sensörleri arasında sensör birleştirme uygulaması yapılmıştır. Robotik sistemler üzerinde yapılan sensör birleştirme işlemi çoğunlukla aynı veri tipine sahip sensör verileri üzerinden yapılmaktadır. Otonom araç donanımında sahip olduğumuz kamera ve LIDAR sensörleri farklı veri tiplerine sahip sensörlerdir. Bu iki sensör arasında veri birleşimi yapılabilmesi için alınan LIDAR verilerinin kamera görüntüsünde olduğu gibi pikseller ile ifade edilmesi gerekmektedir. Böylece aynı veri tipine sahip kamera ve LIDAR verileri arasında birleştirme işlemi yapılabilmektedir. Bu mantık çerçevesinde, LIDAR sensöründen alınan verilerin oluşturduğu nokta uzayı 0-255 arası piksellerden oluşan gri seviyeli bir görüntüye çevrilmiş ve DÖ algoritmalarından olan KSA ağırlarında modellenip kamera modeli ile kaynaştırılarak sensör birleştirme uygulaması yapılmaya çalışılmıştır. Tasarlanan sistemde kamera görüntüleri DÖ modelleri üzerinde eğitilirken, LIDAR verilerinden elde edilen görüntülerde farklı bir DÖ ağırlarında eğitilmiştir. Konvolüsyon katmanlarından geçerek filtrelenen ve özelliği çıkarılan kamera ve LIDAR görüntülerden elde edilen veriler DÖ ağırlarının gizli katmanlarında birleştirilmiştir. Yapılan tüm eğitim veri birleştirme işlemlerinin sonucunda veriler otonom araç kiti üzerinde denenmiştir. Belirlenen parkur içerisinde kullanılan otonom araç kiti ile engelden kaçma ve otonom navigasyon uygulamaları gerçekleştirilebilmiştir. Çalışma kapsamında otonom robotik sistemler, otonom araçlar, sensör birleştirme, DÖ, Robot İşletim Sistemi (ROS) gibi kavramlar üzerinde durulmuştur.

3.1. Otonom Robotik Sistemler

Robotik sistemler, elektrikli ve mekanik sistemlerden oluşmaktadır. Bu sistemler, algılama ve kontrol işlevlerini yerine getirebilen bilgisayar programlamalarına bağlı olarak otonom veya önceden belirlenen görevleri yerine getiren sistemlerdir. Günümüz yaşam koşulları içerisinde robotik sistemler birçok yerde hizmet vermekte ve gün geçtikçe hizmet verdikleri alanlar çoğalmaktadır. Geçmişten günümüze birçok alanda önceden programlanmış robotlar kullanılmaktadır. Bunlar önceden programlanabilen ve yazılımlarında bulunan çalışma prensibine göre faaliyet

gösteren robotlardır. Dolayısıyla herhangi bir sinyal verisini işlemeye gerek duymadan fonksiyonlarını gerçekleştirebilen mekanizmalardır. Genellikle spesifik görevleri yerine getirebilmeleri için tasarlanmışlar ve programlanmışlardır. Endüstriyel platformlarda kullanılan robotik kollar veya manipülatörler büyük ölçüde bu tür işlevler için kullanılmaktadır. Öte yandan popüler robotik sistemlerde ise karar verme yetisine sahip otonom robotların kullanımı yaygınlaşmaktadır. Otonom robotların çalışma prensibi temel olarak, ortamda bulunan sensörlerden elde edilen verilerin robotlar tarafından işlenip anlamlandırılması ve anlamlandırılan bu verilere karşı tepki oluşturulmasına dayanmaktadır (bkz. Şekil 3.1).

Bir robotik sistemin otonom hale gelebilmesi için çevresindeki nesnelere ve olayları algılayabilmesi, bunların varlığında bir karar mekanizması oluşturabilmesi ve bu etmenlerin sonuçlarına bağlı olarak kendisinden beklenen fonksiyonları yerine getirebilmesi gerekmektedir. Dolayısıyla bu tür robotların bulunduğu ortam ile alakalı verileri anlayıp anlamlandırabilmesi için güçlü bir donanıma sahip olması gerekmektedir. Otonom robotların çevresi ile olan etkileşiminin yeterince anlamlı hale gelebilmesi için bünyesinde ses, ısı, ışık ve basınç gibi çevresel etmenleri algılayabilecek sensörler bulundurulmalıdır. Ayrıca robotlar tarafından gerçekleştirilecek olan otonom uygulamalar kapsamında birden fazla sensörün eş zamanlı çalışması sistemi daha kararlı kılmak için önemli bir etkidir.



Şekil 3.1. Otonom robotik sistem yapısı.

3.1.1. Otonom Araçlar

Geçmişte, otonom yapıya sahip robotik sistemler genellikle uzay araştırmalarına konu olmaktadır. Uzayda yapılan incelemelerde elde edilen verilerin kaydedilmesi veya görüntülenebilmesi için mobil yapılar geliştirilmeye çalışılmıştır (Kirk ve ark., 1970). Günümüzde otonom sistemler tüm robotik uygulamalar kapsamında incelenmekte ve geliştirilmektedir. Yapılan çalışmalar doğrultusunda, otonom yapıya sahip robotik sistemlerin insan, hayvan veya yük taşımacılığında kullanılan araçlara aktarılması ile otonom araçlar kavramı ortaya çıkmıştır (Fraedrich ve ark., 2015). Günümüzde özellikle İHA, otonom sürüş donanımına sahip kara araçları ve deniz taşımacılığında kullanılan araçlarda bu yönde olumlu gelişmeler görülmektedir (Tahboub ve ark., 2017; Xu ve ark., 2018).

Yapılan uygulamalar ve geliştirilmek istenen sistemler göz önünde bulundurulduğunda otonom sistemlerin her açıdan kararlı ve yetkin olması gerekmektedir. Özellikle insan hayatı söz konusu olduğunda, karar verme yetisine sahip otonom sistemlerin veya araçların daha donanımlı, kararlı ve yetkin olması gerekmektedir. Dolayısıyla otonom eylemleri sağlayacak karar verme hususunda, otonom araçlarda oluşturulan karar mekanizmaları mümkün olduğunca doğru ve güvenilir olmalıdır. Bunun yanı sıra alınan verilerin hızlı ve doğru bir şekilde işlenmesi ve aktarılması da oldukça önemlidir. Bu işlenen veriler doğrultusunda, otonom araçların içinde buldukları durum ve olaylar karşısında en doğru tepkiyi vermesi gerekmektedir. Dünya çapında yapılan çalışmalarda da otonom araçların gelişimi için bu yönde çok sayıda çalışma ve uygulama gerçekleştirilmiştir.


Otonom araç teknolojisi alanındaki gelişmeler çoğunlukla engelden kaçma, nesne tespiti, yol planlaması, çarpışmalardan kaçınma gibi konular üzerinde yoğunlaşmaktadır. Bu durumda otonom araçlarda çevresel faktörleri algılamada kullanılan sensörlerin çeşitliliği ve hassasiyeti önemli bir hale gelmektedir. Çünkü, otonom araçlardaki karar mekanizması bu sensörlerin verimliliği doğrultusunda ilerlemektedir. Dolayısıyla otonom sistemlerde kullanılacak olan sensörler, sistemin düzgün çalışabilmesi için gerekli olan veriyi sağlayacak nitelikte olmalı ve buna göre sensör tercihiinde bulunulması gerekmektedir.

3.1.1.1. Otonom Araç Sistemlerinde Sensörler

Otonom araçların kara, deniz veya hava ortamlarında kullanımı ile bağlantılı olarak otonom sürüş becerisini geliştirebilmek için birçok sensör kullanılmaktadır. Otonom araçların bulunduğu çevre ile olan etkileşimi kullanılan sensörler ile sağlanmaktadır. Sensörler fonksiyonel nitelikleri bakımından ölçüm yapılan sistem ve ölçüm yapma prensibine göre iki büyük sınıfa ayrılabilir. Ölçüm yapılan sisteme göre Propriyoseptif ve Exteroseptif sensörler bulunmaktadır. Propriyoseptif sensörler, üzerinde buldukları sistemin çalışan öğeleri üzerinde ölçüm yapan sensörlerdir. Bu sensörler ile motor hızı, tekerlek yükü ve akü voltajı gibi kullanılan sistemin kendi parametrelerini ölçülmektedir. Exteroseptive sensörlerle de robotun bulunduğu ortamın özellikleri (ışık yoğunluğu, ses şiddeti, mesafe ölçümleri gibi.) hakkında ölçüm yapılabilmektedir. Otonom sistemlerde çevreyi algılamada da Exteroseptive ölçümler yapabilen sensörler kullanılmaktadır.

Sensörler, ölçüm yapma prensibine göre de pasif ve aktif sensörler olarak gruplandırılabilir. Pasif sensör, çevreden gelen enerjinin veya sinyalin ölçümlerinin sensöre girmesi ile yapılmaktadır. Sıcaklık sensörleri veya mikrofon gibi sensörler pasif sensörlerdir. Aktif sensörler ise çevreye yaydıkları enerjinin veya sinyalin çevreden geri dönen yansımalarına göre ölçüm yapmaktadır. Aktif sensörlerin çevre ile olan bu etkileşimi bu tip sensörlerin daha iyi performans göstermesine olanak sağlamaktadır. Buna karşın aktif sensörden çıkan enerjiler veya sinyaller çevreyi etkileyebilmekte hatta bozulmalara sebep olabilmektedir (Siegwart ve ark., 2011).

Gönderilen ses dalgasının cisimden yansıması ile engelin sensöre olan uzaklığının tespit edilebildiği ultrasonik mesafe sensörleri, gönderilen kızılötesi ışığın engelden yansıması ile engelin sensöre olan uzaklığının tespit edilebildiği kızılötesi mesafe sensörleri veya 360 derece tarama yaparak yansıyan lazer ile engelin uzaklığını tespit edebilen LIDAR gibi sensörler aktif sensörlerdir. Ayrıca çevremizde bulunan tüm nesnelerin görüntülenmesini sağlayan kameralar da aktif sensörler grubuna girmektedir (bkz. Şekil 3.2).



Şekil 3.2. a) Ultrasonik mesafe sensörü, b) Kızıl ötesi mesafe sensörü, c) LIDAR, d) Kamera.

Otonom sistemlere sahip robot platformlarında genellikle bu tip sensör yapıları kullanılmaktadır. Özellikle yolcu taşımacılığında kullanılacak olan otonom araçlarda insan hayatı söz konusu olduğundan kullanılacak olan sensörlerin nitelikleri çok önemlidir. Dolayısıyla hareketi sağlayacak kararı verme hususunda, sensörlerden elde edilen verilerin mümkün oldukça doğru ve güvenilir olması gerekmektedir. Öte yandan, sensörlerin birbirlerine göre avantaj veya dezavantaja sahip olmaları onların birlikte kullanımını gerekli kılmaktadır. Birden fazla sensörün sağladığı veriler birleşmiş halde işlendiğinde daha olumlu sonuçlar verebilmektedir. Böylece birleştirilen sensör verilerinden kaynaklı hatalar ayrı ayrı değerlendirilen sensör hatalarına oranla daha düşük olabilmektedir.

Yapılan sensör birleştirmesi ile daha kararlı ve tamamlayıcı sensör yapıları oluşturulabilmektedir. Sensör verilerini birleştirebilmek için alınan verilerin aynı veri tipinde işlenmesi gerekmektedir. Farklı tipteki veriler tek veri tipinde birleştirildiğinde sensörlerin çevresel faktörlere karşı olan dezavantajlı durumları ortadan kaldırılabilir. Ayrıca herhangi bir sensörün arızalanması veya doğru çalışmaması durumunda diğer sensörlerden alınan veriler sayesinde sistem hatalarından kaynaklı sorunlar azaltılabilmektedir.

3.1.2. Otonom Araç Kiti

Bu tez çalışmasında yapılan sensör birleştirme uygulaması OPENZEKA firmasından temin edilen mini otonom araç kiti üzerinde gerçekleştirilmiştir. Bu tez çalışması dışında firmanın sağlamış oldu platformlarda da otonom sürüş denemeleri yapılmıştır. Ayrıca firma tarafından verilen eğitimler kapsamında otonom araç kitinin kullanımı ile ilgili önemli bilgiler edinilmiştir.

Çalışma kapsamında kullanılan otonom araç kiti, araç yarışları için kullanılan saatte 80km'lik hızlara ulaşabilen esnek ve dayanıklı malzemelerden üretilmiş araç platformu (Traxxas Slash 4x4 Platinum Edition), araç motorlarını sürebilmek için güçlü bir batarya (4200 mAh LiPo 7.4V 25C), pilin daha uzun ömürlü olması ve daha uygun değer aralığında kullanılması için dijital balance profesyonel şarj cihazı, araç üzerinde bulunan sensörlerin bağlantılarının yapılabilmesi için 2 şarj portuna sahip 7 portlu USB3.0 hub, aracın uzaktan kontrolü ve haberleşmesi için Modem (TP-Link Archer C7 Wireless Dual Band Gigabit Router), açık kaynak elektronik hız kontrol (VESC), üç eksenli ivme ölçer IMU (Sparkfun Razor M0 sensörü), bünyesinde çift kamera bulunduran stereo kamera (Stereolabs ZED), 2 boyutlu 360 derece dönüş kabiliyeti bulunan lazer tarayıcı LIDAR (RPLidar A2M6, Scanse Sweep Lidar), aracın manuel kontrolünün yapılabilmesi için oyun konsolu (Logitech F710 Kablosuz Gamepad), işletim sisteminin kurulması ve sensörlerden gelen verilerin depo edilebilmesi için SD kart (Lexar 64GB SDXC UHS-I 633X 95Mb/sn), derin öğrenme uygulamalarında kullanılmak üzere geliştirilmiş NVIDIA işlemcisi (NVIDIA Jetson TX2 Developer Kit), Platform ve Sensörler için batarya (MARC Power Lite) ve Open Zeka tarafından hazırlanan fiber şase ve vida setinden oluşmaktadır (bkz. Şekil 3.3).

Şekil 3.3'de verilen otonom araç geliştirme kitinin ekipmanları OpenZeka firması tarafından hazırlanan araç fiber şase ve vida seti kullanılarak monte edildikten sonraki araç görüntüsü Şekil 3.4'deki gibi olmaktadır. Araç kontrolü, konsol üzerinden yapılmaktadır. Araç tekerleklerinin manevra kabiliyeti ise sağ veya sola 63 derecedir. Eğitim ve test aşamalarında araç teker açıları radyan cinsinden sola dönüşlerde $[-0.35 \ 0]$ aralığında, sağa dönüşlerde ise $[0 \ 0.35]$ aralığında alınmıştır.



Şekil 3.3. a) Araç platformu, b) NVIDIA İşlemci, c) LIDAR, d) Kamera, e) Açık kaynak elektronik hız kontrolcüsü, f) IMU, g) SD kart, h) Modem, ı) 7 girişli USB3.0-hub, i) Lityum Polimer pil, j) Platform ve Sensörler için batarya, k) Joystick.



Şekil 3.4. Otonom araç geliştirme kiti.

3.2. Makine Öğrenmesi

Günümüz teknolojisinin hızla ilerlemektedir. Teknolojik gelişmelerin her biri bir sonraki gelişmeyi daha da hızlandırmakta ve yeni yeni çalışma alanları oluşturmaktadır. Gelecek yıllarda hayatın her alanında söz sahibi olabilecek çalışma alanlarından biri de YZ alanıdır. YZ kavramı, teorik olarak Turing (1950) tarafından makinaların zeki olup olmadığını test eden çalışmasıyla ortaya çıkmıştır. Resmi olarak YZ teriminin kullanılması ise 1956 yılında Dartmouth Koleji'nde yapılan bir konferansta gerçekleşmiştir. Daha sonra 1970'li yıllarda hastalık teşhisinde kullanılabilir olması gelişimine hız kazandırmış, 1980'li yıllarda o yıllardaki güncel uygulamalarda kullanılması ile günümüze kadar gelmiş ve birçok alanda meydana gelen problemler için uyarlanarak gelişimine devam etmektedir (Özşahin, 2019).

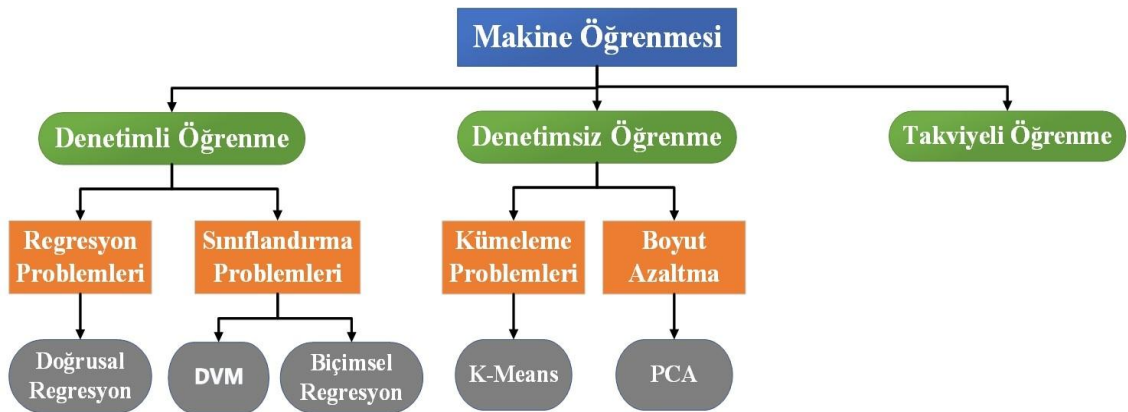
Genel bir tabirle YZ, insan düşünce sisteminin ve öğrenebilme kabiliyetinin yazılımlar aracılığıyla bilgisayarlara veya makinelere aktarılmasıdır (Göranzon ve Florin, 2012). YZ, insan düşünce sistemi temel alındığından Bilgisayar bilimi, Psikoloji, Nöroloji, Matematik, Sosyoloji ve Felsefe gibi bilim dalları ile alakalı geniş bir yelpazeye sahiptir. Bu alanlarda çözümler arama ve ilerlemeler kaydedilmesi için bilgisayar teknolojilerinin kullanılması ile karar verme yetisine sahip makineler geliştirilmeye çalışılmıştır. Bu karar verme mekanizmalarının bilgisayar yazılımları ile oluşturulması ve bunların makineler üzerinde uygulanması ile birlikte YZ çalışma alanının bir alt dalı olan Makine Öğrenmesi (MÖ) kavramı ortaya çıkmıştır. Aslında

MÖ tarihsel süreç içerisinde YZ konusunda yapılan araştırmalar ve uygulamalar sonucunda ortaya çıkmıştır (Carbonell ve ark., 1983).

MÖ kavramı, bulunulan ortam içerisinde elde edilen verilerin ölçülen veya bilinen özelliklerine dayanarak eğitilmiş ve öğrenilmiş verilerden tahminde bulunulabilecek sistem bütününden oluşmaktadır. Dolayısıyla MÖ sistemlerindeki temel amaç, ortamdan alınan giriş verisini kullanabilen algoritmalar ile çıkış verisi üretebilmek ve bunu öğrenebilmektir. Sistem performansına bağlı olarak zaman içerisinde değişen ya da güncellenen giriş verilerine bağlı olarak kullanılan algoritmalara göre yeni çıkış değerlerini istatistiksel olarak tahmin edebilmektir. MÖ girdi ve çıktı parametreleri arasındaki ilişkiye göre genel olarak üç grupta incelenmektedir. Bunlar; girdi parametreleri ile çıktı parametrelerinin birbirine etiketlendiği Denetimli Öğrenme, sadece girdi verilerinin bilindiği Denetimsiz Öğrenme ve deneme yanılma yoluyla oluşan girdilerden ödül ve ceza uygulanarak çıktı oluşturulan Takviyeli öğrenme yöntemleridir (bkz. Şekil 3.5).


Denetimli öğrenme sınıflandırma ve regresyon problemlerinden oluşur. Sınıflandırma, alınan bir örneğin özelliklerine göre çıktı gruplarından hangisine ait olduğunu tahmin edilmesidir. Regresyon ise alınan bir örneğin sürekli bir çıktı içerisinde tahmin edilmesidir.

Denetimsiz öğrenme kümeleme ve boyut azaltma problemlerinden oluşur. Kümeleme, alınan örneklerin benzer özelliklerine göre bir arada toplanmasıdır. Boyut Azaltma ise alınan örneklerin özelliklerinden sonuca etkisinin az olduğu özelliklerinin çıkarılmasıdır.



Şekil 3.5. Makine Öğrenmesi.

Bu çalışma kapsamında üzerinde durduğumuz YZ tekniği ise DÖ kavramıdır. Derin öğrenme, makine öğrenmenin alt dallarından biri olan ağlarda eğitilen verilerin her birini önceden katmanlarında ayrı ayrı eğiten bir sistemdir (LeCun ve ark., 2015). DÖ yapısı, MÖ algoritmalarının birkaçının birlikte kullanılması ile oluşturulmuş bir YZ tekniğidir. Ayrıca büyük veri setleri üzerinde MÖ algoritmalarından farklı olarak yapılacak hesaplamaları birçok katmanda tek seferde yapabilmektedir. Kısacası DÖ, YZ kümesinde bulunan MÖ algoritmalarının birkaçının bir araya getirilerek oluşturulduğu spesifik bir alt alandır (bkz. Şekil 3.6).



Şekil 3.6. Yapay zeka alt dalı olan Derin Öğrenme.

3.2.1. Derin Öğrenme (DÖ)

DÖ son zamanlarda birçok robotik problemi çözmek için kullanılmaktadır. Nesne algılama, Lokalizasyon, Sınıflandırma ve kontrol gibi çoğu alanda etkili olmaktadır. Bu kadar geniş bir alanda kullanılmasındaki en önemli etken gerçek ortamdaki elde edilen işlenmemiş ve kompleks verilerden makine öğrenme işlevini yerine getirerek birçok probleme çözüm üretebilmesidir. Bu da derin öğrenmeyi birçok otonom robotik uygulama için ön plana çıkarmaktadır.


Aslında derin öğrenmenin kökeni 1971 yılında, 8 katmanlı bir sinir ağının Grup Veri İşleme Yöntemi algoritması kullanılarak eğitilmesine dayanmaktadır (Ivakhnenko ve Cybernetics, 1971). 80'li yıllarda derin öğrenme kavramı matematiksel bir hesaplama modeli olarak görülmekteydi (Fukushima, 1988). DÖ kavramı ise 90'lı yıllara gelindiğinde görsel nesne tanıma işlevini gerçekleştirebilmesi için eğitildiği süreçte oluşmuştur (LeCun ve ark., 1998). 2000'li yıllarda ise derin öğrenme kavramı üzerinde büyük sıçramalar meydana gelmiştir. Bu gelişmeler aslında bilgisayar teknolojileri ile yakından alakalıdır. O zamana kadar ki bilgisayar teknolojisinin yavaş olması ve veri setindeki azlık derin öğrenmenin performansını olumsuz yönde etkilemekteydi. NVIDIA'nın Grafik İşlemci Birimini (GPU) güçlendirmesi ve paralel

hesaplama mimarisi olan CUDA'yı geliştirmesiyle daha çok veriyi daha hızlı işleyen bilgisayarlar üretilmiştir (NVIDIA Corporation, 2019a). Teknolojideki birçok ilerleme ile birlikte, 1.2 milyon görüntünün 1,000 kategoride sınıflandırılabilirdiği veri setinin de yayınlanmasıyla veri seti problemi de aşılmış derin öğrenme hızla popüler hale gelmiştir (Deng ve ark., 2009). Böylece kullanım alanı oldukça genişleyen derin öğrenme görsel nesne tanıma yanı sıra ses tanıma, dil bilgisi işleme ve sinyal verisi işleme gibi alanlarda da hızla kullanılmaya başlamıştır (Bengio ve ark., 2013). Derin öğrenmenin birçok probleme karşı elde ettiği başarılar otonom robotik sistemlere de yansımıştır. Dolayısıyla derin öğrenme yapısının kullanımı kara, deniz ve hava araçlarında otonom sistemler geliştirilmesine de katkıda bulunmuştur.

3.2.1.1. Derin Öğrenme Algoritmaları

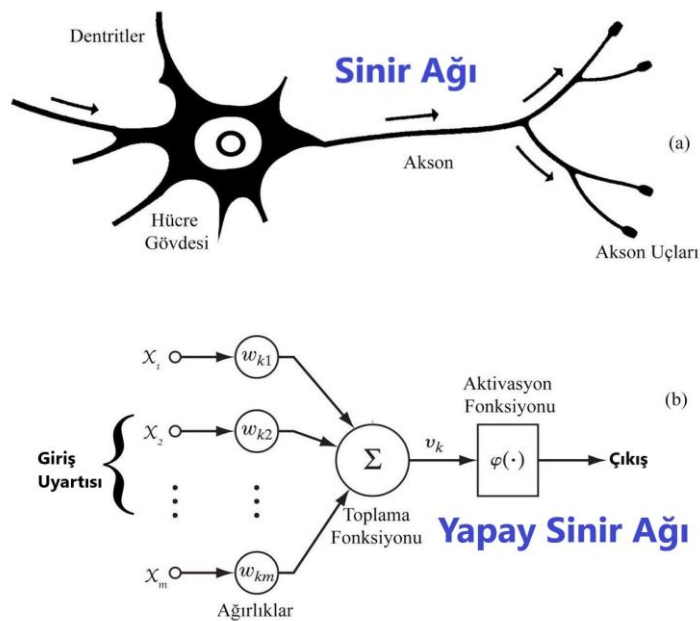
Sistematik olarak DÖ birkaç MÖ algoritmasının birleştirilmesiyle oluşmuştur. Çözülmesi istenen problemlerin niteliklerine göre DÖ algoritmaları 3 grupta incelenebilir. Bunlar; Derin Sinir Ağları (DSA), Konvolüsyonel Sinir Ağları (KSA) ve Tekrarlayan Sinir Ağları (TSA) olarak adlandırılabilir (bkz. Şekil 3.7).

Derin öğrenme algoritmalarının yapısında bulunan sinir ağları kavramı insan beyninden esinlenerek oluşturulmuş ve insan beyninin işleyişini mantıksal olarak taklit eden bir benzetimdir (Schmidhuber, 2015). Bu algoritmaların tarifinde kullanılan sinir ağları kavramı insan beynini oluşturan nöronlardan yola çıkılarak oluşturulmuştur. Birbiri ile bağlantılı olan bu nöron gruplarının oluşturduğu yapıya sinir ağı denmektedir. İnsan beyninin çalışma mekanizmasını taklit eden bu yapay sinir ağları; öğrenme, hatırlama, genelleme yapma ve yeni bilgileri öğrendiği verilerden türetebilme gibi insan beyninin temel işlevlerini gerçekleştirmek için oluşturulmuş mantıksal yazılımlarla ifade edilen algoritmalarlardır. Kısacası, YZ tekniklerinin içeriğinde bulunan sinir ağ yapıları, sinir sistemini inceleyen Nöroloji bilimi kapsamındaki sinir hücrelerinin biyolojik fonksiyonlarının yazılım bilimindeki algoritmalarla ifade edilmesinden ibarettir.



Şekil 3.7. Derin Öğrenme Algoritmaları.

Sinir sisteminde bulunan kavramlar, sinir ağlarının matematiksel modelinin oluşturulmasında kullanılmıştır. Sinir hücresi olarak adlandırılan nöronlar, yapay sinir ağlarında işlem elemanıdır. Dentrit, sinir hücresinin uçlarından bulunan dallanmış yapılardır. Diğer hücreler arası iletişimde önemli rol oynamaktadır. Dentritler yapay sinir ağlarında toplama fonksiyonu olarak adlandırılmıştır. Sinir hücrelerinin organellerinin bulunduğu gövde kısmı ise Aktivasyon fonksiyonu olarak adlandırılmıştır. Uyarıların taşındığı yol olarak nitelendirilebilecek aksonlar da çıkış elemanı olarak adlandırılmıştır. Son olarak, nöronların akson ucu ile dentritlerinin birbirine bağlandığı yer olan sinapslar ise ağırlıklar olarak adlandırılmıştır (bkz. Şekil 3.8) (Grossi ve ark., 2007).




Şekil 3.8. Gerçek Sinir ağı ve Yapay sinir ağı (Grossi ve ark., 2007).

Yapay sinir ağlarında sisteme ait özellik verileri giriş değişkenleri (x_m) olarak ifade edilir. Her özellik verisi önem derecesine göre ağırlık (w_{km}) değeriyle çarpılır. Ağırlıkları alınmış giriş verileri toplanarak aktivasyon fonksiyonundan ($\varphi(\cdot)$) geçirilir. Çıkış değeri $y(x)$, güncelleme sırası k olmak üzere yapay sinir ağları için matematiksel formülü Denklem (3.1)'de gösterildiği gibidir.

$$y(x) = \varphi\left(\sum_{i=1}^m w_{ki}x_i\right) \quad (3.1)$$

DÖ algoritmalarından en basit yapıda olan DSA modeli bu sinir ağ yapılarından oluşmaktadır. DSA algoritması içerisinde nöronların bulunduğu üç katmandan oluşmaktadır. Bunlar; giriş katmanı, gizli katman ve çıkış katmanıdır (bkz. Şekil 3.9) Bu algoritmanın derin olarak adlandırılmasındaki temel etken, yapısında bulunan katman sayısının ikiden fazla olmasıdır (Hinton, 2007).




Şekil 3.9. DSA ağ yapısı.

DSA algoritması birbirine bağlı paralel katmanlarda matematiksel hesaplamaların yoğunlukta olduğu sınıflandırma ve tahmin modellerini içeren algoritmalar. Algoritmalara girdi olarak verilecek dataların ağ yapılarında anlamlandırılabilmesi için özelliklerinin çıkartılması gerekmektedir. Ağa sunulan veriler, ağ tarafından tahminde bulunulurken her bir verinin kendine has özellikleri sayesinde birbirinden ayırt edilebilmektedir. Algoritmaya sunulan özelliği çıkarılmış eğitim verileri katmanlar arasındaki bağların matematiksel fonksiyonları sayesinde öğrenilir. Daha sonra gelecek olan verilerin sonuçları katmanlar arasındaki matematiksel fonksiyonlar kullanılarak tahmin edilir. DSA algoritması genellikle çıkış

katmanında elde edilen sonuç verilerinin birbirinden ayırt edilebildiği sınıflandırma problemlerinde kullanılmaktadır (Larochelle ve ark., 2009; Cireşan ve ark., 2010).

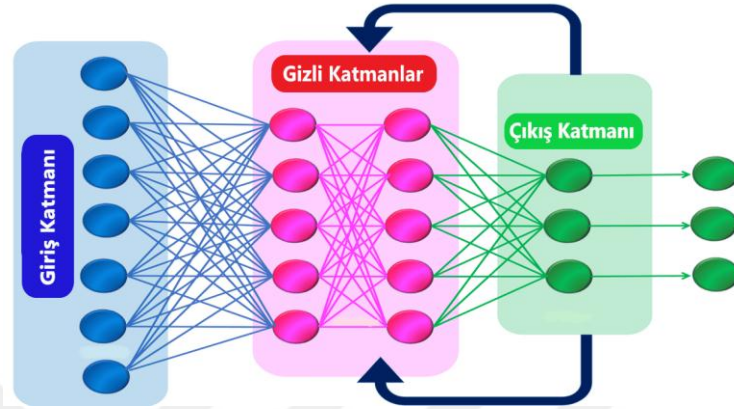
DSA algoritmasına göre biraz daha gelişmiş olan DÖ algoritması ise KSA algoritmasıdır. Bu algoritmanın DSA algoritmasına göre en temel farkı, özellik çıkarma işleminin konvolüsyon katmanlarında otomatik ve rasgele yapılmasıdır (bkz. Şekil 3.10). Konvolüsyon katmanında giriş verisine uygulanabilen çok sayıda ve rasgele filtreler sayesinde kullanıcının DSA algoritmasında olduğu gibi özellik çıkartma işlemini ayrıyeten yapmasına gerek yoktur. Böylece çok daha büyük verilerin sinir ağ yapılarına iletilecek özellik verileri, daha ayrıntılı ve daha çeşitli bir şekilde elde edilebilmektedir. KSA algoritmaları özellikle giriş verisi olarak görüntülerin kullanıldığı nesne algılama, engel tanıma ve nesne takibi gibi birçok uygulamada kullanılmaktadır.



Şekil 3.10. KSA ağ yapısı (NVIDIACorporation, 2019b).

Temel DÖ algoritmalarından üçüncüsü ise TSA algoritmasıdır. Bu algoritma, sıralı ilişkilere sahip olaylar, dil modelleri veya zaman serisi içinde bulunan olayların eğitilmesi ve makinalar tarafından öğrenilebilmesi için kullanılmaktadır (bkz. Şekil 3.11). KSA, genellikle görüntü tanıma ve nesne sınıflandırması için kullanılan ileri beslemeli bir sinir ağı iken, TSA bir katmandan geçen verinin çıktısını kaydetme ve giriş verilerine geri besleme uygulayarak katmanın çıktısını tahmin etme mantığıyla oluşturulmuş bir DÖ algoritmasıdır. TSA algoritmasında önceki girişler hafızada tutulabildiğinden alınan yeni bir giriş verisi önceki giriş verileri ile birlikte dikkate alınarak algoritmada işleme tabi tutulabilir.

YZ kavramının insan düşünce ve mantık sistemine sahip makineler oluşturabilmek olduğunu göz önüne aldığımızda kabaca DÖ algoritmalarından KSA algoritmasının insan gözünü, TSA algoritmasının da insan dili ve kulağını temsil ettiği düşünülebilir.



Şekil 3.11. TSA ağ yapısı.

3.3. Robot İşletim Sistemi (ROS)

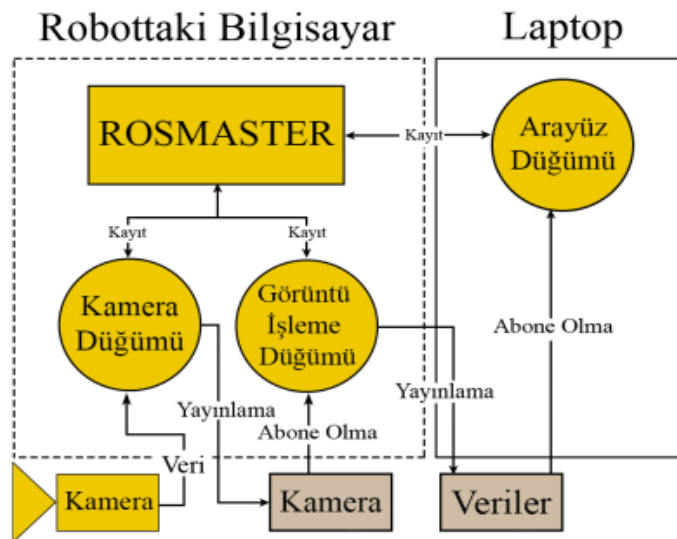
İş ve sosyal hayatın her alanına yayılmakta olan robotik sistemlerde son yıllarda oldukça hızlı ve önemli gelişmeler yaşanmıştır. Endüstriden eğlenceye, sağlıktan askeri alanlara birçok sektörde otonom sistemler geliştirilmeye çalışılmaktadır. Dünyanın farklı bölgelerinde yaşanan gelişmeler kimi zaman birbiri ile örtüşmektedir. Dolayısıyla robotik uygulamaların birbirlerine katkıda bulunabilmesi dünya çapında bilgi ve uygulama paylaşımları olması ve bunlara hızlı bir şekilde ve kolayca ulaşılabilmesi oldukça önemlidir. Ayrıca yazılım ve donanım geliştirici robotik uygulamalarda robotik aksam üzerinde bulunan birçok bileşenin uyumlu ve senkronize olarak aynı anda çalışması hala çeşitli robotik uygulamalar için problem teşkil etmektedir. ROS bu tür gelişmelere büyük katkılar sağlayabilecek bir platform niteliğindedir.

ROS, her ne kadar robot işletim sistemi olarak adlandırılırsa da bütünüyle bir işletim sistemi değildir. Daha doğru bir ifadeyle ROS, robotik yazılımların gerçekleştirildiği, çeşitli robotik alanlarda robotlar için belirlenen oldukça karmaşık ve zorlu görevleri robot ya da kullanıcı açısından kolaylaştırmayı hedefleyen, içerisinde robotik araçları ve yazılım kütüphaneleri bulunduran açık kaynak koduna sahip bir robotik yazılım platformudur (ROS). Özellikle YZ konusunda insanlar açısından kolay gözükse de bazı işlevsel hareketler robotlar açısından oldukça karmaşık ve zorlu

olabilmektedir. ROS, bu konuda robotik sistem uygulamalarına farklı açılardan oldukça makul yöntemler sunabilmektedir (ROS).

ROS platformunun çalışma sistemi 'rosmaster' ağ yapısı içerisinde gerçekleşir. Bu ağ içerisinde yayıncı (publisher) ve abone (subscriber) bulunur. Birbiri ile veri alışverişinde olan yayıncı ve abone arasındaki bağlantı düğüm (node) olarak ifade edilir. Bu düğümlerde veriler belli bir konu başlığı (topic) altında yayınlanabilir. Aynı zamanda bu yayınlanan veriler aynı konu başlığı altında abone olunarak da elde edilebilir. Ayrıca bu düğümlerde hesaplama işlemleri de gerçekleştirilebilmektedir. Rosmaster ağ yapısı içerisinde yapılan uygulamaların kapsamına bağlı olarak bünyesinde birçok yayıncı, abone, başlık ve düğüm barındırabilir (O'Kane, 2014).

Teknolojik gelişmelere bağlı olarak üretilen birçok robot artık ROS platformuna uyumlu bir şekilde üretilmektedir. Buda, ROS platformunun robotik sistemlerin kullanıldığı her alanda yaygınlaşmasına olanak sağlamaktadır. Ayrıca ROS platformunun gerçek zamanlı uygulamalar ile eş zamanlı çalışabilen simülasyonları da bünyesinde barındırması bu platformu daha tercih edilebilir hale getirmektedir. Askeri alanlar, endüstriyel platformlar ve hizmet alanları gibi geniş bir yelpazede kullanım olanağı bulunmaktadır. Özellikle eş zamanlı ve birbirine bağlı çalışan robotik sistemlerde ROS tercih edilmektedir. ROS çalışma prensibine örnek olabilecek bir görsel Şekil 3.12'de verilmiştir. Bu tez kapsamında da kamera ve LIDAR verilerinin elde edilmesi ve aktarılması LINUX işletim sistemi üzerinden çalıştırılan ROS platformu tarafından sağlanmıştır.



Şekil 3.12. ROS çalışma prensibi (Kaya, 2017).

4. UYGULAMA VE SONUÇLAR

Yapılan tez çalışması kapsamında otonom araç kiti ile yapılan uygulamada araç üzerinde bulunan kamera ve LIDAR sensör verileri arasında sensör birleştirme işlemi gerçekleştirilmiştir. Araç kiti için hazırlanan platformda engelden kaçınma ve navigasyon uygulamaları yapılmıştır. Otonom araç kiti üzerinde bulunan kamera ve LIDAR sensörlerinden alınan verilerin birleştirilmesi yapılmadan önce parkurda sergilediği performans ile birleştirilmesi yapıldıktan sonraki performansları değerlendirilmiş ve otonom sürüş sistemine olan katkısı irdelenmiştir.

4.1. Veri Seti Oluşturma

Eğitim ve test işlemlerini gerçekleştirmek için kullanılacak veri seti RACLAB (Robotik-Otomasyon Kontrol Araştırma Laboratuvarı) laboratuvar ortamında kurulan parkur içerisinde toplanmıştır (bkz. Şekil 4.1). Kartonlardan ve muşambalardan oluşturulan parkurda aracın manuel kontrolleri konsol kullanılarak yapılmıştır. Sürüş esnasında araç üzerinde bulunan kamera sensöründen alınan görüntüler ve LIDAR sensöründen alınan nokta uzayı verileri kaydedilmiştir. Öncelikle kurulan parkur etrafında düz ve ters yönde olmak üzere ikişer tur tamamlanmıştır. Daha sonra aracın otonom sürüş esnasında karşılaşılabileceği farklı senaryolar için karton kenarlarında, köşelerde, dar ve keskin virajlarda aracın konumunu değiştirerek tekrar görüntü ve nokta uzayı verileri toplanmıştır (bkz. Şekil 4.2). Ayrıca ışık yoğunluğunun yüksek ve düşük olduğu parkur bölümlerinde de tekrar görüntü ve nokta uzayı verileri alınmıştır. Toplanan LIDAR verilerinin oluşturduğu nokta uzayı da veri toplama sırasında anlık olarak gri seviyeli görüntülere çevrilmiştir. Yapılan tüm veri seti oluşturma çalışmaları sonucunda 5,126 kamera görüntüsü ve 5,126 gri seviyeli LIDAR görüntüsü elde edilmiştir.

Oluşturulan veri setinin giriş parametreleri kamera ve LIDAR görüntülerinden oluşmaktadır. Veri setinde bulunan çıkış parametresi ise araç konsolu ile yapılan sürüş esnasında aracın tekerlerinin dönüş açılarıdır. Aracın parkurda yaptığı sürüş esnasında sağa dönüşlerde $[0 \ 63]$ ve sola dönüşlerde $[-63 \ 0]$ derece aralığında alınan teker açıları, radyan değerlere normalize edilerek $[-0.35 \ 0.35]$ aralığındaki açılara dönüştürülmüştür.



Şekil 4.1. Parkur.



Şekil 4.2. Muhtemel senaryolar için veri setini çoğaltma.

Araç tekerlerinden alınan bu $[-0.35 \ 0.35]$ aralığındaki radyan açı değerleri anlık olarak alınan görüntülerle etiketlenmiştir. Kamera, LIDAR görüntülerinden oluşan giriş verilerine ve araç teker açılarından oluşan çıkış verilerine sahip bu veri seti daha sonraki aşamalarda bir DÖ modeli olan KSA katmanlarında eğitilmiştir.


4.1.1. LIDAR nokta uzayından görüntü elde edilmesi

Araç üzerinde bulunan LIDAR sensörü araç etrafında bulunan engellerin yerini noktasal olarak tespit etmektedir. Bu sensör, aracın etrafında bulunan engellerin araca olan uzaklık verisini sağlamaktadır. Araç kiti üzerinde bulunan RPLIDAR A2 lazerli tarayıcı sensörü 2 boyutlu 360 derecelik açıyla 25 metreye kadar tarama kapasitesine sahiptir fakat kurulan pistin özellikleri göz önünde bulundurulduğunda 10 metrelik mesafelerden alınan veriler yeterli olmaktadır. Dolayısıyla LIDAR sensörünün menzili 10 metre olarak alınmıştır. LIDAR ile oluşturulan veri setinde bir saniyede 3,600 adet nokta tespiti yapılmıştır. Araç etrafında oluşturulan bu nokta uzayındaki 0-10 m aralığındaki engel mesafeleri, [0 1] aralığında normalize edilmiştir. Daha sonra normalize edilen bu değerler 255 ile çarpılarak [0 255] aralığındaki gri seviyeli görüntü piksellerine dönüştürülmüştür (Denklem 3.2).

$$GSP(x) = \frac{X}{10} \cdot 255 \quad (3.2)$$

Burada, LIDAR sensöründen elde edilen nokta uzayına karşılık gelen gri seviyeli piksel değerleri (GSP), engelin LIDAR sensörüne olan uzaklığı da X'dir. Oluşan piksellerdeki beyaz ve açık tonlar engelin daha uzak mesafelerde bulunduğunu, gri ve koyu tonlar ise engelin daha yakın mesafelerde bulunduğu ifade etmektedir.

Yapılan dönüşüm sonrasında elde edilen [0 255] aralığındaki tek boyutlu matris, LIDAR sensörünün bir turda belirlediği 360 noktaya bağlı olarak 20×18 boyutunda gri seviyeli bir görüntüye dönüştürülmüştür. Sonuç olarak, her biri LIDAR verisinden 360 adet noktayı içeren 20×18 boyutunda gri seviyeli görüntüler elde edilmiştir. Toplanan bu veri seti ile yapılan eğitimlerde araç otonom sürüşü gerçekleştirememiştir. Yapılan denemeler sonucunda LIDAR sensörüne yakın olan araç parçalarının da engel olarak görüldüğü tespit edilmiştir. Yapılan tespitler sonucunda, LIDAR sensörünün dönüşü sırasında aracın LIDAR'a yakın olan kısımlarının da engel olarak algılanmaması için 15 cm veya daha yakın mesafedeki araç parçalarından gelen mesafe ölçümleri piksel değeri olarak 255'e eşitlenmiştir. Böylece, bu bölümlerin engel olmadığı resimlerde beyaz renk olarak ifade edilmiştir. LIDAR verilerinin ROS paketinde (R-viz) oluşturduğu harita görüntüsü ve bu verilerin işlenmesi sonucunda oluşan gri seviyeli görüntülerden biri Şekil 4.3'de verilmiştir.



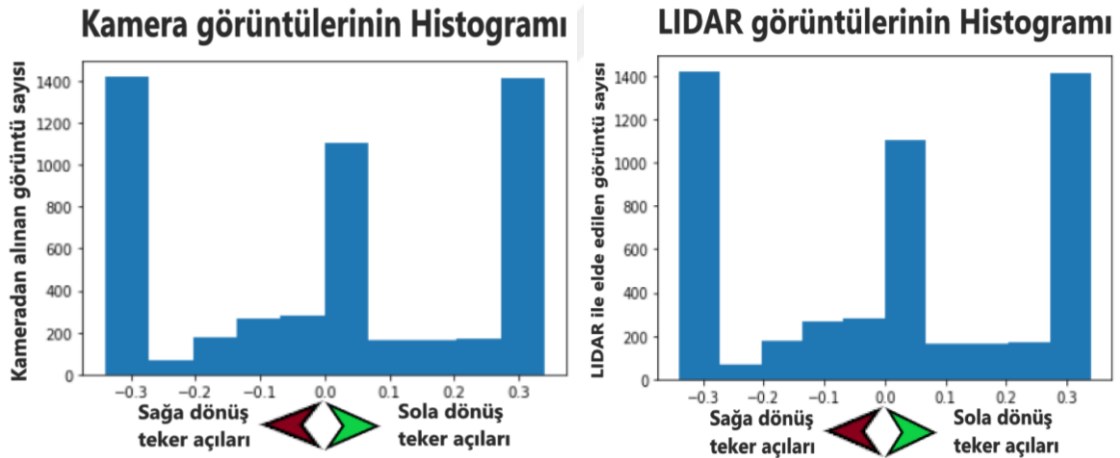
Şekil 4.3. a) Aracın parkurda bulunduğu konum, b) Parkurda LIDAR sensöründen alınan R-viz görüntüsü, c) Gri seviyeli görüntü.

Oluşturulan veri setindeki gri seviyeli resimlere çıktı değeri olarak $[-0.35 \ 0.35]$ arasındaki radyan teker açıları atanmıştır. Kullanılacak olan ağ modelinde bu açı değerlerine göre eğitim ve test işlemleri yapılmıştır.

4.1.2. Veri Seti Çoğaltma

ZED kamera üzerinde iki adet kamera barındırmaktadır. Veri seti oluşturulurken kamera görüntülerinin hep aynı tipte olması aracın sağlıklı bir şekilde öğrenmesini zorlaştırmaktadır. Bu nedenle hem veri çeşitliliğini artırmak hem de veri setini genişletmek için ZED kamerada bulunan iki kameradan aynı anda alınan görüntüler tek çerçevede sunulmuştur. Böylece, iki kameradan alınan görüntülerin tek karede birleştirilmesi ile daha geniş açıyı görüntüleyebilen bir görüntü elde edilmiştir.

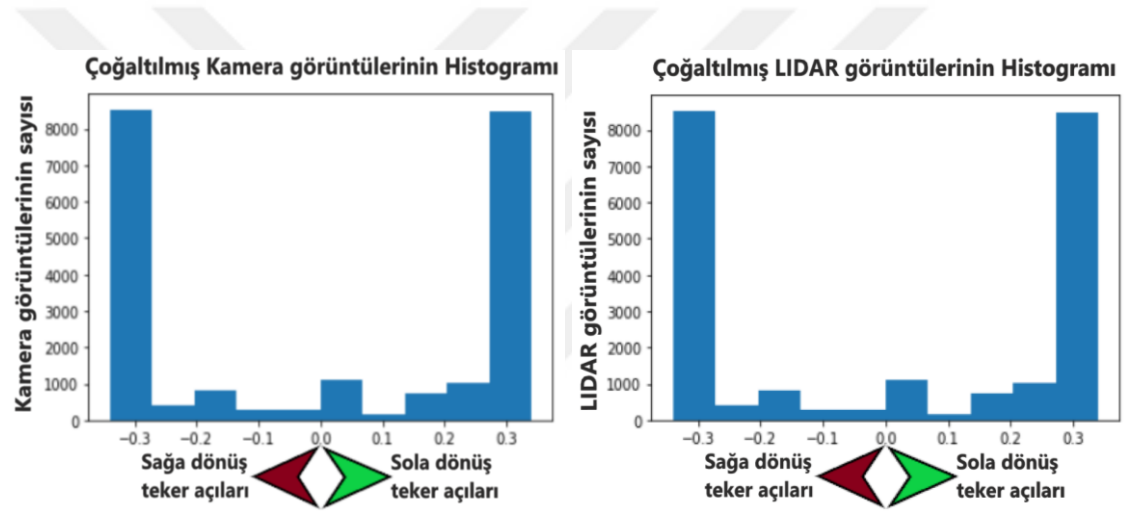
Mini otonom araç, parkur üzerinde hareket halindeyken alınan kamera görüntüleri ve LIDAR verilerinden elde edilen görüntülerin histogram eğrisi Şekil 4.4'deki gibidir. Burada, araç hareket halindeyken teker açılara karşılık gelen anlık görüntülerin veri seti içerisindeki yoğunluğu ifade edilmektedir. Grafiğin yatay ekseninde bulunan negatif (-) değerler sola, pozitif (+) değerler ise sağa dönüşte kaydedilen radyan cinsinden açılarını ifade etmektedir.



Şekil 4.4. a) Kamera görüntülerinden oluşturulan Histogram b) LIDAR görüntülerinden oluşturulan Histogram.

Öte yandan toplanan bu görüntüler ile yapılan eğitimde 0 ve 0'a yakın radyan cinsinden açı değerlerine karşılık gelen görüntü sayısının fazla olduğu görülmektedir. Yapılan otonom sürüş testleri sırasında da aracın düz gitme eğiliminde olduğu ve tekerlerinde titremeler olduğu gözlemlenmiştir. Araç parkurda yapılan uygulamalar sırasında çoğunlukla düz giderek bariyerlere çarpmaktadır. Keskin virajlarda ise virajın bitmesine rağmen dönüşüne devam ederek bariyerlere çarpmaktadır. Aracın dönüşler ile alakalı verileri daha iyi öğrenebilmesi için histogram eğrilerinde 0.15'den büyük

açıların etiklendiği görüntüler ile -0.15 'den küçük açıların etiklendiği görüntülerin sayısı 5 kat artırılarak yeni veri seti oluşturulmuştur. Oluşturulan veri setinin histogram eğrisi Şekil 4.5'de verilmiştir. Oluşturulan bu yeni veri seti ile yapılan denemelerde ise aracın parkuru ezberlediği ve parkurda yapılan küçük değişikliklere karşı hassas olduğu görülmüştür. Bu problemde önüne geçmek, veri setindeki çeşitliliği arttırmak ve ezberi önlemek için veri setinde bulunan resimlerden rastgele seçilen resimlerin parlaklıkları değiştirilmiştir. Rastgele seçilen resimlerden bazılarının parlaklığı artırılırken bazılarının ki azaltılmıştır. Böylece birbirine yakın ve art arda alınan görüntüler arasında parlaklıktan kaynaklı farklar oluşmuştur. Bu parlaklık farkı sayesinde eğitim ve test aşamalarında aynı görüntülerde bulunabilecek küçük farklılıkların da öğrenilmesi sağlanmıştır.



Şekil 4.5. a) Çoğaltılmış Kamera görüntülerinden oluşturulan Histogram b) Çoğaltılmış LIDAR görüntülerinden oluşturulan Histogram.


4.2. KSA Algoritması ile Eğitim ve Test İşlemleri

Kamera ve LIDAR sensörlerinden alınan görüntüler yaygın olarak kullanılmakta olan DÖ algoritmalarından KSA ağ yapısında eğitilmiştir. Öncelikle Kamera görüntüleri ve LIDAR verilerinden elde edilen görüntüler teker teker eğitilmiştir. Sonrasında da Kamera LIDAR birleştirme işlemi yapılarak eğitilmiştir. Bu eğitimler daha önce oluşturulan veri setinin %80'i üzerinden yapılmıştır. Geriye kalan %20'lik kısmı ile de eğitilen ağlar test edilmiştir. Eğitim ve test işlemlerinde çıkış değerinin ağ içerisinde daha verimli bir şekilde kullanılabilmesi için elde edilen görüntüler ile etiketlenen teker açıları 3 ile çarpılarak daha geniş bir matrise yayılmıştır. Bunun sonucunda teker açıları $[-0.35 \ 0.35]$ aralığından $[-1.05 \ 1.05]$ aralığına taşınmıştır.

Buradaki temel amaç normalizasyon işlemi yapıldığında verilerin sonuçlarının daha geniş bir aralıkta olması ve giriş verisi ile çıkış verisi arasındaki karşılaştırmanın daha kolay yapılabilmesidir.

4.2.1. Kamera Görüntülerinin Eğitimi ve Testi

ZED kameradan alınan görüntüler eğitilmeden önce görüntülerde parkur dışında kalan alanlar kesilmiş ve resimlerin piksel değerleri azaltılarak eğitime işlemi uygulanmıştır. Kameradan alınan 500×1470 piksel boyutuna sahip olan resimler kırılarak 376×1344 piksellik boyutlara düşürülmüştür. Böylece eğitim ve test işlemleri için gereken görüntülerdeki fazlalıklar elimine edilmiştir. Aynı zamanda eğitim ve test işlemleri için harcanan zamandan tasarruf edilmiştir. Kırılan görüntülerden oluşturulmuş kamera veri seti yaygın olarak kullanılan DÖ algoritmalarından KSA ağ modellerinde eğitilmiş ve test edilmiştir. Tasarlanan birçok ağ modelinin denenmesi sonucunda kamera görüntüleri için kullanılan en verimli KSA ağ modeli Şekil 4.6'da gibidir.

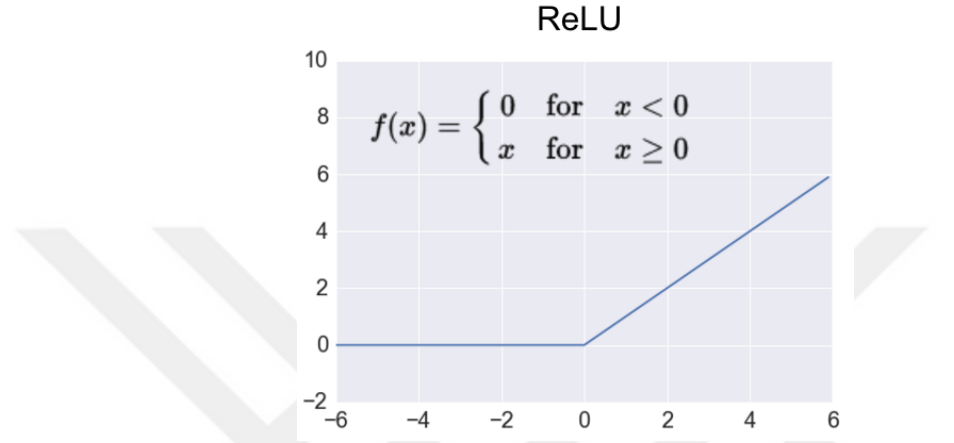


Şekil 4.6. Kamera görüntülerinin eğitimi için tasarlanan KSA ağ yapısı.

Kullanılan bu ağ modelinde resimler öncelikle konvolüsyon katmanında belirlenen boyutlardaki filtrelerden geçirilir. Filtrelerden geçirilen bu resimlerin, sınır ağlarında eğitilmek üzere özellikleri çıkarılmış olur. Özelliği çıkarılan bu resimler, sınır ağlarında eğitilerek çıkışta teker açılı ile eşleşir. Tasarlamış olduğumuz ağ yapısında resimler, 7 adet konvolüsyon katmanından geçtikten sonra Tam Bağlı Katmanlara (TBK) iletilmektedir. Konvolüsyon katmanlarında resimlere sırasıyla 3×3 boyutunda 80 adet Kernel (Filtre), 2×2 boyutunda 64, 32, 32, 16 ve 8 adet Kernel uygulanmıştır. Ayrıca, eğitim işlemini hızlandırmak ve piksel kaybına uğramadan resim boyutunu küçültmek için 3. konvolüsyon katmanında 2×2 boyutunda bir adet MaxPooling


katmanı uygulanmıştır. Uygulanan MaxPooling katmanı ile çıkarılan özellikler kayba uğramaksızın resmin boyutu yarıya düşürülmüştür.

Eğitim sırasının ağırlık sahibi olduğu ağırlıklar güncellenirken parametre değerlerinin yüksek basamaklara ulaşip ağı yavaşlatmaması için her konvolüsyon katmanında bu değerleri normalize etmek için Doğrultulmuş Lineer Birim (Relu) aktivasyon fonksiyonu kullanılmıştır (bkz. Şekil 4.7).



Şekil 4.7. Doğrultulmuş Lineer Birim (Relu) aktivasyon fonksiyonu (Bayramli, 2019).

Aktivasyon fonksiyonlarından geçen çok boyutlu matrisler TBK katmanlarına iletilmek için düzleştirme-indirgeme (flatten) katmanından geçirilerek tek boyuttaki matrislere dönüştürülmüştür. Oluşan tek boyutlu matrisler sırasıyla 1024, 256, 64 ve 16 nöronun bulunduğu 4 adet TBK katmanında eğitilmiştir. Ayrıca, 1024 nörona sahip TBK katmanının ardından ağ ezberinin önüne geçebilmek için 0.2 oranında seyreltme (dropout - ağırlıkların güncellenmesi sırasında nöronların %20 rasgele seçilip çıkışa etkisinin sıfırlanması) uygulanmıştır. Konvolüsyon katmanında olduğu gibi TBK katmanlarında da Relu aktivasyon fonksiyonu kullanılmıştır. Son olarak tek çıkışlı sonuç katmanında ise teker açılarının $[-1.05 \ 1.05]$ arasında olmasından dolayı daha verimli bir şekilde normalize edeceğinden Şekil 4.8'de verilen Hiperbolik Tanjant (tanh) aktivasyon fonksiyonu kullanılmıştır.



Şekil 4.8. Hiperbolik Tanjant (tanh) aktivasyon fonksiyonu (Bayramli, 2019).

Eğitimler esnasında hata (Loss) fonksiyonu olarak Denklem (4.1)'de verilen Ortalama Kare Hatası (MSE-mean squared error) kullanılmıştır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (4.1)$$

Burada, y_i veri setinde bulunan gerçek teker açısı, \tilde{y}_i tasarlanan KSA ağ modeli tarafından tahmin edilen teker açısı olmak üzere; gerçek değerler ile tahmini değerler arasındaki farkların karelerinin ortalaması Ortalama Kare Hatası (MSE) değerini vermektedir.

TBK katmanlarında ağ öğrenmesi için kullanılan ağırlıkların güncellenmesi ve çıkışa adapte olabilmesi için Adadelta optimizasyon fonksiyonu kullanılmıştır. Veri seti üzerinden oluşturulan ağırlık verilerinin güncellemeleri uzun süren denemeler sonucunda, sinir ağında 30 iterasyonda (epoch) gerçekleştirilmiştir. Optimizasyon ile ağırlık güncellemesinde çarpan olarak kullanılan öğrenme oranı (lr- learning rate) değeri 1.0 olarak alınmıştır. Bu değer aynı zamanda Adadelta optimizasyon fonksiyonunun varsayılan değeridir. Tek seferde ağa sunulacak olan resim sayısını olarak adlandırılan 'batch size' değeri de 2 alınarak eğitimler yapılmıştır. KSA katmanında eğitim işlemi için kullanılan parametreler Çizelge 4.1'de verilmiştir.

Çizelge 4.1. KSA ağ modelinde bulunan parametre değerleri.

Parametreler	
Optimizasyon Fonksiyonu	Adadelta
Hata Fonksiyonu (loss)	Ortalama Hata Karesi (MSE)
Aktivasyon Fonksiyonları	ReLu,TanH
Öğrenme Oranı (lr)	1.0
İterasyon sayısı (Epoch)	30
Batch Size	2
Validation Split	0.2
Seyreltme (Dropout)	0.2

Yapılan eğitimler veri setinin %80'i üzerinden yapılmıştır. Kalan %20'lik kısmı ile de eğitilen ağın test işlemi yapılmıştır. Test için ağa sunulan resimlerin çıkış değerleri [-1.05 1.05] değerleri arasında olduğundan 3'e bölünüp tekrar gerçek teker açığı aralığı olan [-0.35 0.35] aralığına çekilmiştir. Uygulanan eğitimim modelinin program tarafından oluşturulan özet çıktısı Çizelge 4.2'de verilmiştir.

Çizelge 4.2. Kamera ağ modelinin özeti.

Katman (tipi)	Çıkış Boyutu	Parametre Sayısı #
cropping2d_1 (Cropping2D)	(None, 126, 1344, 3)	0
lambda_1 (Lambda)	(None, 126, 1344, 3)	0
conv2d_1 (Conv2D)	(None, 62, 671, 80)	2240
conv2d_2 (Conv2D)	(None, 31, 335, 64)	20544
max_pooling2d_1 (MaxPooling2)	(None, 15, 167, 64)	0
conv2d_3 (Conv2D)	(None, 14, 166, 32)	8224
conv2d_4 (Conv2D)	(None, 13, 165, 16)	2064
conv2d_5 (Conv2D)	(None, 12, 164, 8)	520
flatten_1 (Flatten)	(None, 15744)	0
dense_1 (Dense)	(None, 1024)	16122880
dropout_1 (Dropout)	(None, 1024)	0
dense_2 (Dense)	(None, 256)	262400
dense_3 (Dense)	(None, 64)	16448
dense_4 (Dense)	(None, 16)	1040
dense_5 (Dense)	(None, 1)	17


Toplam parametre sayısı: 16,436,377

Eğitilebilen parametre sayısı: 16,436,377

Eğitilememiş parametre sayısı: 0

4.2.2. LIDAR Verilerinden Elde Edilen Görüntülerinin Eğitimi ve Testi

LIDAR nokta bulutu verisinden dönüştürülerek oluşturulan gri seviyeli 20×18 boyutundaki görüntüler Şekil 4.9’de verilen ağ yapısı kullanılarak eğitilmiştir.



Şekil 4.9. LIDAR görüntülerinin eğitimi için tasarlanan KSA ağ modeli.

Kullandığımız bu ağ modelinde resimler konvolüsyon katmanında belirlenen boyutlardaki filtrelerden geçirilerek özelliği çıkarılır. Özelliği çıkarılan bu resimler eğitildikten sonra çıkışta teker açıları ile eşleşir. Tasarlamış olduğumuz ağ yapısında resimler, 6 adet konvolüsyon katmanından geçirildikten sonra TBK katmanına iletilmektedir. Konvolüsyon katmanlarda resimlere sırasıyla 2×2 boyutunda 64, 32, 32, 16, 16 ve 8 adet Kernel uygulanmıştır. Ağın eğitimi yapılırken yavaşlamaması ve ağırlıkların doğru bir şekilde güncellenmesi için her konvolüsyon katmanında, bu değerleri normalize etmek için Relu aktivasyon fonksiyonu kullanılmıştır. Aktivasyon fonksiyonlarından geçen çok boyutlu matrisler TBK katmanına iletmek için flatten katmanından geçirilerek tek boyuttaki matrislere dönüştürülmüştür. Oluşan tek boyutlu matrisler kamera görüntülerinin eğitiminde olduğu gibi sırasıyla 1024, 256, 64 ve 16 adet nöronun bulunduğu 4 adet TBK katmanında eğitilmiştir. Konvolüsyon katmanında olduğu gibi TBK katmanlarında da Relu aktivasyon fonksiyonu kullanılmıştır. Son olarak tek çıkışlı sonuç katmanında ise teker açılarının $[-1.05 \ 1.05]$ arasında olmasından dolayı Şekil 4.8’de verilen tanh aktivasyon fonksiyonu kullanılmıştır.

KSA katmanında eğitim işlemi için kullanılan parametre değerleri Kamera görüntülerinin eğitimi için kullanılan parametreler ile aynıdır ve Çizelge 4.1’de verilmiştir. Yine kamera görüntülerinin eğitiminde olduğu gibi eğitimler veri setinin %80’i üzerinden yapılmış, kalan %20’lik kısmı ile de ağın test işlemi yapılmıştır. Test için ağa sunulan resimlerin çıkış değerleri 3’e bölünüp tekrar gerçek teker açı aralığı

olan $[-0.35 \ 0.35]$ aralığına çekilmiştir. Uygulanan eğitimim modelinin özeti Çizelge 4.3’de verilmiştir.

Çizelge 4.3. LIDAR ağ modelinin özeti.

Katman (tipi)	Çıkış Boyutu	Parametre Sayısı #
conv1d_1 (Conv1D)	(None, 19, 64)	2368
lambda_1 (Lambda)	(None, 19, 64)	0
conv1d_2 (Conv1D)	(None, 18, 32)	4128
conv1d_3 (Conv1D)	(None, 17, 16)	1040
conv1d_4 (Conv1D)	(None, 16, 8)	264
flatten_1 (Flatten)	(None, 128)	0
dense_1 (Dense)	(None, 1024)	132096
dropout_1 (Dropout)	(None, 1024)	0
dense_2 (Dense)	(None, 256)	262400
dense_3 (Dense)	(None, 64)	16448
dense_4 (Dense)	(None, 16)	1040
dense_5 (Dense)	(None, 1)	17
=====		
Toplam parametre sayısı: 419,801		
Eğitilebilen parametre sayısı: 419,801		
Eğitilememiş parametre sayısı: 0		
=====		

4.2.3. Sensör Birleştirmesi ile Elde Edilen Verilerin Eğitimi ve Testi

Parkurda manuel sürüşleri yapılan otonom araç kitinin Kamera ve LIDAR sensörlerinden alınan verileri sürüş esnasında eş zamanlı olarak toplanmıştır. Kamera ve LIDAR sensöründen elde edilen görüntüler KSA ağ modelinin konvolüsyon katmanlarından ayrı ayrı geçirilerek özellikleri çıkarılmıştır. Çıkarılan bu özellik verileri flatten katmanından geçirilerek tek boyuttaki matrislere dönüştürülmüştür.

Kamera görüntülerinden elde edilen tek boyutlu özellik matrisinin özellik elemanları LIDAR görüntüsünden elde edilen özellik elemanlarına göre oldukça fazladır. Veriler, eğitime işlemi yapılmadan önce bu halleriyle birleştirme edildiğinde eğitim sonrası yapılan testlerde, kamera verilerinden alınan sonuçlar otonom sürüş esnasında daha ağır basmaktadır. Dolayısıyla bunun önüne geçebilmek için birleştirme işlemini gerçekleştirilmeden önce bu veriler 1024 nörona sahip TBK’dan geçtikten

Çizelge 4.4. Birleştirilen ağ modelinin özeti.

Katman (tipi)	Çıkış Boyutu	Param #	Bağlı
input_1 (InputLayer)	(None, 376, 1344, 3)	0	
input_2 (InputLayer)	(None, 20, 18)	0	
sequential_1 (Sequential)	(None, 1024)	3352376	input_1[0][0]
sequential_2 (Sequential)	(None, 1024)	139896	input_2[0][0]
concatenate_1 (Concatenate)	(None, 2048)	0	sequential_1[1][0] sequential_2[1][0]
sequential_3 (Sequential)	(None, 1)	6574433	concatenate_1[0][0]
Toplam parametre sayısı: 10,066,705			
Eğitilebilen parametre sayısı: 10,066,705			
Eğitilememiş parametre sayısı: 0+			

4.3. Eğitim ve Test Sonuçları

Otonom araç kiti ile parkurda yapılan sürüş esnasında oluşturulan veri seti ile DÖ algoritmalarından KSA ağ yapısında eğitim ve test işlemleri yapılmıştır. Toplanan verilerin %80'i eğitim, %20'si test verisi için kullanılmıştır. Kamera, LIDAR ve Birleştirilmiş veriler ile yapılan eğitim ve test işlemleri sonucunda alınan değerler Tablo-3' gösterildiği gibidir. Alınan sonuçlara göre Birleştirme işleminden sonra tüm hata fonksiyonlarında daha iyi sonuçlar gözlemlenmektedir. Gerçek değer ile tahmini değer arasındaki hatayı hesaplamak için kullanılan Loss fonksiyonu MSE olarak seçilmiştir. Ortalama kare hata olarak kullanılan MSE, bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu söylemektedir. MSE, makine öğrenmesi modellerinde sıklıkla kullanılmaktadır. Öğrenme sonucunda üretilen tahmini değerlerin performansını ölçmek için tercih edilmektedir. Daima pozitif değere sahiptir. Performans kriteri olarak MSE değerinin 0'a yakın olması öğrenme sonucunda üretilen tahminlerin gerçek değere yakın olduğunu ve eğitime işleminin verimli olduğunu göstermektedir. Buna karşın, bu değer makine öğrenme uygulamalarında sıfır olması istenmez. Bu ağın öğrenmediğinin ezberlediğinin bir göstergesi olarak kabul edilir. Ağ modelleri ile yapılan eğitim ve test sonucunda elde edilen eğitim hata fonksiyonu değeri (Loss), eğitim doğruluk değeri (Accuracy), test hata fonksiyonu değeri (Validation Loss) ve test doğruluk değeri (Validation Accuracy) Çizelge 4.5'de verilmiştir. Burada; Loss, eğitim esnasında girdi ile çıktı arasındaki MSE değeridir. Accuracy, eğitim esnasında ağın

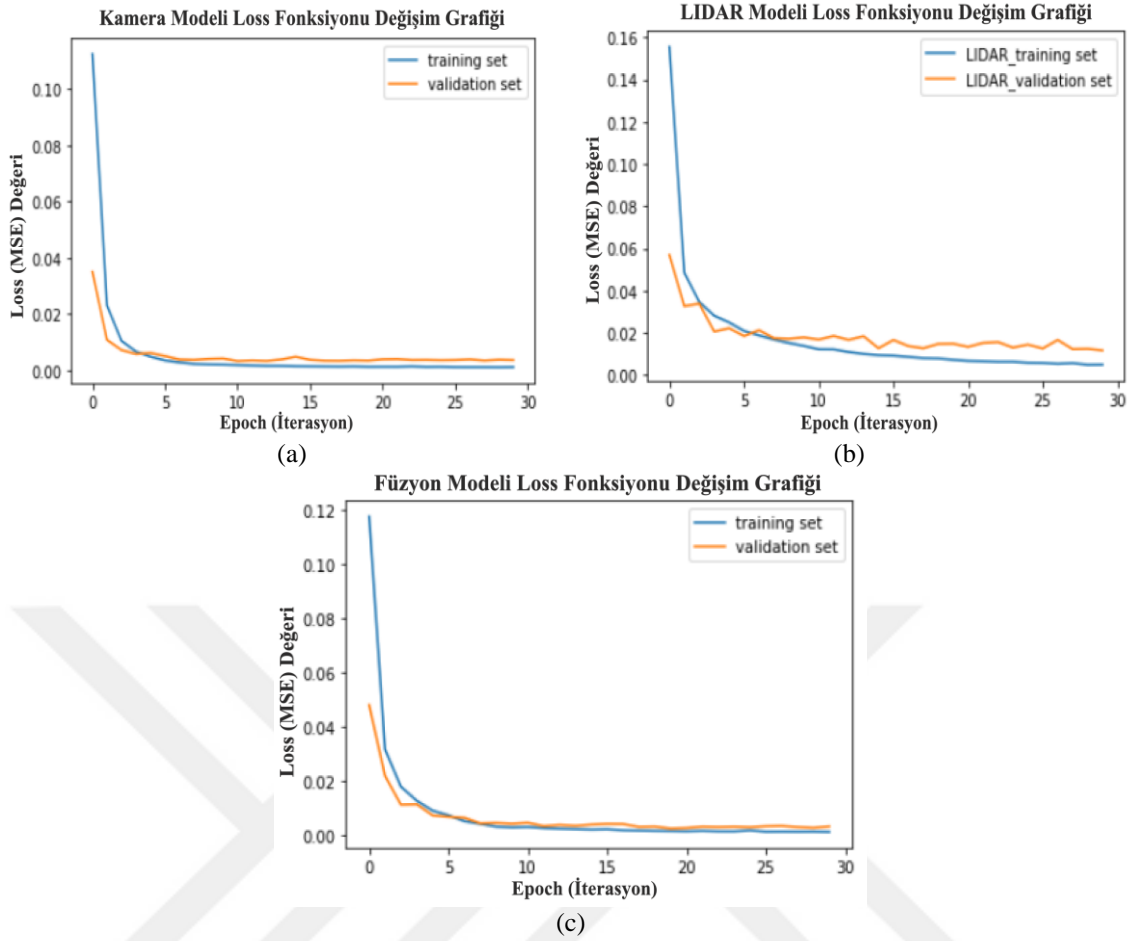
doğru tahminde bulunduğu çıktı oranıdır. Validation Loss, test esnasında girdi ile çıktı arasındaki MSE değeridir. Validation Accuracy ise test esnasında ağın doğru tahminde bulunduğu çıktı oranıdır.

Çizelge 4.5. KSA ağ modelinde bulunan parametre değerleri.

Hata Fonksiyonları	Kamera Hata Oranı	LIDAR Hata Oranı	Birleştirme Hata Oranı
Loss (MSE)	0.0020	0.0048	0.0009
Accuracy	0.0388	0.0386	0.039
Validation Loss (MSE)	0.0037	0.0116	0.0041
Validation Accuracy	0.0361	0.0347	0.0376

Çizelge 4.5’de verilen değerlere göre Loss hata değerleri çok düşük olmasına rağmen açı değerlerinin doğru tahmin edilmesi için elde edilen accuracy değerleri de çok düşüktür. İlk bakışta sistemin doğru çalışmadığı düşünülse de yapılan denemeler ve araştırmalar gösterdi ki, teker açı değerlerinin tanh aktivasyon fonksiyonundan geçirildikten sonra [-1 1] aralığında olması ve bu aralığa karşılık gelen açı değerlerin 70 adet olması tahmin edilen açı değerlerinin gerçek değer ile arasındaki çok küçük farkların bile hata olarak algılanmasına neden olmaktadır. Örneğin; radyan cinsinden 0.35 değerinde olan 63 derecelik gerçek açı değeri yapılan testler sonucunda 0.343 radyan olarak tahmin edildiğinde 61 dereceye tekabül etmektedir. Burada radyan açı cinsinden 0.007 gibi çok küçük bir fark olmasına rağmen normal açı değerinde 2 derecelik bir sapma vardır. Dolayısıyla buradaki hata sadece matematiksel fonksiyonların bir getirisi olarak karşımıza çıkmaktadır. Sadece matematiksel olarak görünen hata gerçek zamanlı otonom sürüşlerde etkisiz olmaktadır. Araç bu oranlarla sorunsuz bir şekilde parkuru otonom olarak tamamlamıştır.

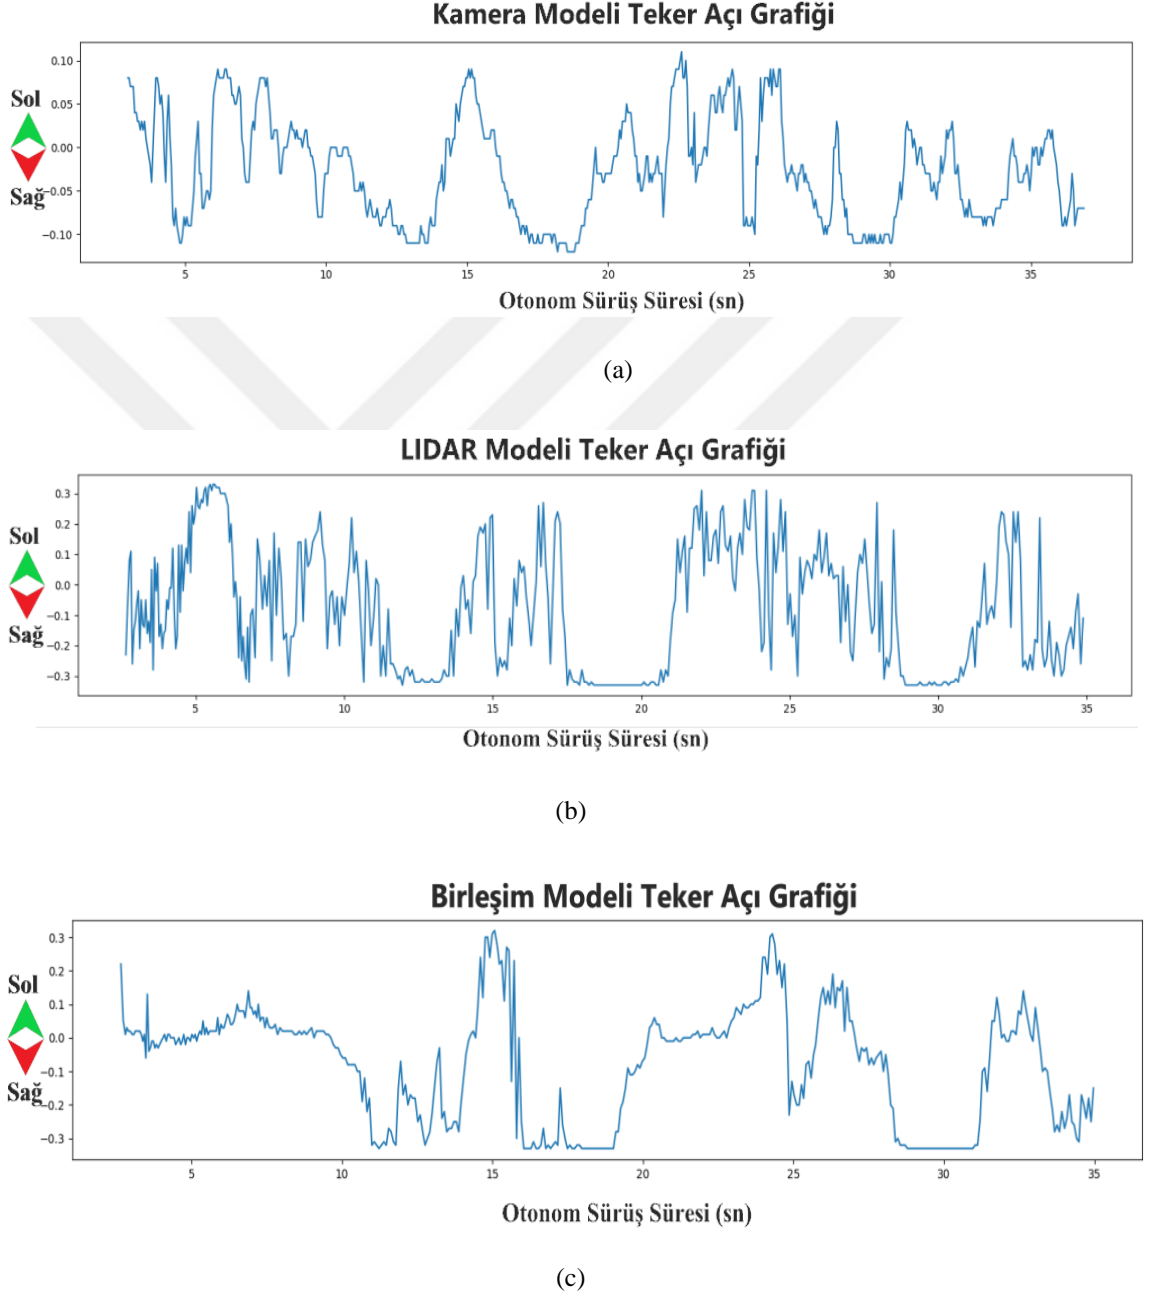
Bunun yanı sıra, diğer bir değerlendirme kriteri olarak kamera, LIDAR ve birleştirilmiş veriler ile yapılan eğitim ve test süresince hata fonksiyonlarında meydana gelen değişimler Şekil 4.11’de gösterilmiştir. Eğitim ve test hata fonksiyonlarındaki değişimlerin birbirine yakın çıkması yapılan eğitime işleminin verimli olduğunun bir göstergesidir. Kamera ve LIDAR hata fonksiyonlarındaki değişimlere nazaran birleştirilmiş veriler ile yapılan eğitim ve test hata sonuçların birbirine daha yakın olması sistemin kamera ve LIDAR’a göre daha verimli çalışabileceğinin bir göstergesidir. Eğitim ve test sonuçlarında alınan bu veriler doğrultusunda araç üzerinde denemeler yapılmıştır. Veri setinin toplandığı parkurda aracın otonom bir şekilde engellere çarpmadan turlarını tamamlayabildiği gözlemlenmiştir.



Şekil 4.11. a) Kamera verisi eğitim ve test hata fonksiyon grafiği, b) LIDAR verisi eğitim ve test hata fonksiyon grafiği, c) Birleştirme verisi eğitim ve test hata fonksiyon grafiği.

Araç parkuru ezberledi mi yoksa gerçekten öğrendi mi anlamak için parkur üzerinde değişiklikler yapılmış ve otonom sürüş bu değişikliklerin olduğu yeni parkurda tekrar denenmiştir. Denemeler sonucunda, aracın otonom sürüş yaptığı yeni parkuru da engellere çarpmadan tamamlayabildiği gözlemlenmiştir. Bir diğer karşılaştırma kriteri olarak, aracın parkuru dolaşırken ki teker açı değerlerindeki değişimleri kamera, LIDAR ve birleştirilmiş modeller için kaydedilmiştir (Şekil 4.12). Kaydedilen değerler göz önünde bulundurulduğunda birleştirilmiş modelin daha verimli bir otonom sürüş gerçekleştirdiği gözlemlenmiştir. Kamera modeli ile yapılan otonom sürüş esnasındaki teker açı grafiğine göre teker açılarının sık sık pozitif ve negatif olarak değişmesi aracın parkur içinde yalpalamalar yaptığının bir göstergesidir. LIDAR modeli ile yapılan otonom sürüş esnasındaki teker açı grafiğine göre teker açılarının çok hızlı bir şekilde değişmesi de aracın tekerlerinde otonom sürüş esnasında titremelerin olduğunun bir göstergesidir. İki sensörün birleştirilerek yaptığı sürüşte ise sistem kameraya göre daha az yalpalamış, LIDAR' a göre ise daha az titreme yapmıştır. Dolayısıyla uygulanan

sensör birleştirme tekniği ile daha az enerji sarf edilmiş ve daha verimli bir otom sürüş gerçekleştirilmiştir. Ayrıca, aracın daha az titreme ve yalpalama yapması parkuru daha hızlı bir şekilde tamamlamasını da sağlamıştır. Kamera ve LIDAR ile 35-40 saniye aralığında tamamlanan parkur birleştirme algoritması ile 27-32 saniye aralığına kadar düşebilmiştir.



Şekil 4.12. a) Kamera modeli teker açığı grafiği, b) LIDAR modeli teker açığı grafiği, c) Birleşim modeli teker açığı grafiği.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Kamera ve LIDAR sensörleri otonom araçlarda kullanılan vazgeçilmez sensörlerdendir. Düşük maliyetteki kamera ve LIDAR sensörleri dikkate alındığında, kamera gündüz ve kötü hava koşullarında iyi performans gösterirken LIDAR ise gece ve iyi hava koşullarında daha iyi performans göstermektedir. Birbirleri arasında tamamlayıcı niteliğe sahip bu iki sensör arasında veri birleştirme işlemi yapılmaya çalışılmıştır. Böylece sensörlerin farklı durumlarda birbirlerinin hatalarını telafi edebilmesi sağlanmıştır.

Bilgisayar ortamında alınan sonuçlar gerçek zamanlı olarak otonom araç kiti üzerinde denenmiştir. Önceden hazırlanan araç parkurunda veri toplama işlemi yapılmış ve eğitim ve test verileri üzerinden parkurda otonom sürüşler gerçekleştirilmiştir. Yapılan otonom sürüş ile bilgisayar ortamında yapılan eğitim ve test verileri örtüşmektedir. Araç, parkuru ters ve düz olmak üzere engellere çarpmadan otonom bir şekilde tamamlamıştır.

Yapılan uygulamada mini otonom araç kiti üzerinde bulunan kamera ve LIDAR sensöründen farklı veri tipine ait değerler alınmaktadır. Birleştirme işleminin yapılması için bu veri tipleri aynı veri formatına dönüştürülmesi gerekmektedir. Lazerli radar sensörü olan LIDAR engel tespitinde nokta bulutu verisini sağlamaktadır. Araç etrafında bulunan alanı lazer ışınları ile taramakta ve geri yansıyan ışıkları referans olarak ortamdaki nesnelere uzaklık bilgisini verebilmektedir. Kamera ise ortamdaki aldığı üç boyutlu görüntülerin RGB katmanlarındaki piksel değerlerini verebilmektedir.

Bu çalışma kapsamında, LIDAR nokta bulutundaki veriler gri seviyeli piksel değerlerini içeren görüntülere çevrilmiştir. LIDAR verilerinden çevrilen bu görüntüler ile kameradan alınan görüntüler DÖ algoritmalarından biri olan KSA ağ yapısında eğitilmiş ve test edilmiştir.

Sadece kamera ile yapılan eğitim ve test sonuçlarına göre otonom araç parkuru küçük hatalarla tamamlamaktadır fakat ortamda meydana gelebilecek ışık yoğunluğundaki değişimler aracı olumsuz etkilemekte ve aracın parkurun kenarlarına çarpmasına neden olmaktadır. Sadece LIDAR verilerinden elde edilen görüntülerle yapılan sürüşlerde araç tekerlerinde aşırı yalpalanma ve titremeler gözlemlenmektedir.

Dolayısıyla kamera ve LIDAR sensörleri tek başlarına kullanıldıklarında kısıtlı alanlarda olumlu sonuçlar alınabildiği ifade edilebilir.

Kamera ve LIDAR verileri ile yapılan birleştirme işlemi sonrasında yapılan test sürüşlerinde aracın LIDAR sensöründen kaynaklı olan yalpalama ve titreme sorununun gözle görülür bir biçimde azaldığı gözlemlenmiştir. Buda, aracın otonom bir şekilde parkuru daha hızlı tamamlamasına olanak sağlamıştır. Ayrıca ortam ışıklandırmasında meydana gelen parlaklık artışı veya azalışından kaynaklı kameraya bağlı sıkıntılarında birleştirme sistemiyle büyük ölçüde aşıldığı test sürüşleri esnasında gözlemlenmiştir.

Bunların yanı sıra, otonom sürüş esnasında sensörlerden birinde yaşanabilecek beklenmedik bir arıza durumunda kamera veya LIDAR sensörlerinin birbirleri yerine kullanılabilmesi otonom sürüş için oldukça önemli bir kazanımdır. LIDAR sensörünün engel tespitinde bulunmasının yanı sıra kamera gibi nesne tespitinde KSA katmanlarını kullanması kameradan kaynaklı arızalarda LIDAR'ın sistemi idare edebilecek nitelikte olmasını sağlamaktadır.

Geliştirilen bu sistem daha az gelişmiş kamera ve LIDAR sensörleri ile gece yapılan otonom sürüşlerde kameranın yetersiz kalması veya teknik sorunlar çıkarması durumunda LIDAR ile bu eksiklik giderilebilecektir. Sisli veya yağmurlu vb. kötü hava koşullarında da LIDAR verilerindeki sapmalar kamera verileri ile giderilebilecektir. Böylece hem daha verimli bir otonom sürüş gerçekleştirilmiş olacak hem de sensör kayıplarından kaynaklanabilecek sorunlar azaltılabilecektir.

5.2 Öneriler

Yapılan uygulamalar sonucunda mini otonom araç üzerinde geliştirilen sistem otonom araçlar için Kamera ve LIDAR sensörü kaynaklı hata ve eksiklikleri en aza indirmede yetkin sonuçlar vermektedir. Dolayısıyla gelişmiş sensör yapılarının pahalı olma faktörüne karşı geliştirilebilir bir alternatif sunabilmektedir. Gelişime açık olan bu yapı kamera ve LIDAR sensörünün birlikte kullanıldığı birçok otonom sistem üzerine adapte edilebilir ve otonom robotik sistemin daha verimli çalışmasına katkıda bulunabilir.

Bu çalışmanın sonraki aşamalarında da otonom sürüş için farklı birleştirme teknikleri denenecektir. Kamera ve LIDAR sensörü dışında IMU gibi farklı sensör verilerinin de farklı yöntemler ile birleştirilmesi sistem hatalarını daha çok azaltabilir. Ayrıca stereo kameraların derinlik verileri ile LIDAR verilerinin birlikte işlenmesi

sađlanıp engel tespitinde daha verimli sonuçlar alınabilir. Bu sonuçlar ile 2 boyutlu görüntüler üzerinde birleştirme yapıp daha etkin bir otonom sistem oluşturulabilir.

Daha güçlü kameralar ya da çok boyutta tarama yapabilen LIDAR sensörlerinin temin edilebilmesi ile elde edilecek daha verimli ve doğru sensör verileri ile yapılacak birleştirmeler ile çok daha gelişmiş ve her alana adapte olabilecek otonom robotik sistemler geliştirilebilir. Sadece otonom araç teknolojisi değil birçok robotik sektörde de verimli sonuçlar gözlemlenebilir.



KAYNAKLAR

- Adarsh, S., Ramachandran, K. J. A. C. ve Sciences, C., 2018, Design of Sensor Data Fusion Algorithm for Mobile Robot Navigation Using ANFIS and Its Analysis Across the Membership Functions, 52 (5), 382-391.
- Asama, H., Fukuda, T., Arai, T. ve Endo, I., 2013, Distributed autonomous robotic systems 2, Springer Science & Business Media, p.
- Bayramli, B., 2019, Yapay Sinir Ağları (Neural Networks), https://burakbayramli.github.io/dersblog/algs/mlp/yapay_sinir_aglari__neural_networks_.html:
- Bengio, Y., Courville, A., Vincent, P. J. I. t. o. p. a. ve intelligence, m., 2013, Representation learning: A review and new perspectives, 35 (8), 1798-1828.
- Bostanci, E., Bostanci, B., Kanwal, N. ve Clark, A. F. J. S. C., 2018, Sensor fusion of camera, GPS and IMU using fuzzy adaptive multiple motion models, 22 (8), 2619-2632.
- Bruno, D. R. ve Osório, F. S., 2017, Image classification system based on deep learning applied to the recognition of traffic signs for intelligent robotic vehicle navigation purposes, *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, 1-6.
- Carbonell, J. G., Michalski, R. S. ve Mitchell, T. M. J. A. M., 1983, Machine learning: a historical and methodological analysis, 4 (3), 69-69.
- Chavez-Garcia, R. O. ve Aycard, O. J. I. T. o. I. T. S., 2016, Multiple sensor fusion and classification for moving object detection and tracking, 17 (2), 525-534.
- Chen, J., Miao, X., Jiang, H., Chen, J. ve Liu, X., 2017, Identification of autonomous landing sign for unmanned aerial vehicle based on faster regions with convolutional neural network, *2017 Chinese Automation Congress (CAC)*, 2109-2114.
- Ciresan, D., Meier, U., Gambardella, L. ve Schmidhuber, J., 2010, Deep big simple neural nets excel on handwritten digit recognition. CoRR abs/1003.0358 (2010).
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. ve Fei-Fei, L., 2009, Imagenet: A large-scale hierarchical image database, *2009 IEEE conference on computer vision and pattern recognition*, 248-255.
- Dieterle, T., Particke, F., Patino-Studencki, L. ve Thielecke, J., 2017, Sensor data fusion of LIDAR with stereo RGB-D camera for object tracking, *2017 IEEE SENSORS*, 1-3.
- Fraedrich, E., Beiker, S. ve Lenz, B. J. E. J. o. F. R., 2015, Transition pathways to fully automated driving and its implications for the sociotechnical system of automobility, 3 (1), 11.

- Fukushima, K. J. N. n., 1988, Neocognitron: A hierarchical neural network capable of visual pattern recognition, 1 (2), 119-130.
- Garcia, F., Martin, D., De La Escalera, A. ve Armingol, J. M. J. I. I. T. S. M., 2017, Sensor fusion methodology for vehicle detection, 9 (1), 123-133.
- Gaya, J. O., Gonçalves, L. T., Duarte, A. C., Zanchetta, B., Drews, P. ve Botelho, S. S., 2016, Vision-based obstacle avoidance using deep learning, *2016 XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR)*, 7-12.
- Göranzon, B. ve Florin, M., 2012, Artificial Intelligence, Culture and Language: On Education and Work, Springer Science & Business Media, p.
- Grossi, E., Buscema, M. J. E. j. o. g. ve hepatology, 2007, Introduction to artificial neural networks, 19 (12), 1046-1054.
- Hinton, G. E. J. T. i. c. s., 2007, Learning multiple layers of representation, 11 (10), 428-434.
- Ivakhnenko, A. G. J. I. t. o. S., Man, ve Cybernetics, 1971, Polynomial theory of complex systems, (4), 364-378.
- Karasulu, B. ve Korukoglu, S. J. E. S. w. A., 2012, Moving object detection and tracking by using annealed background subtraction method in videos: Performance optimization, 39 (1), 33-43.
- Kaya, Ö. F., 2017, ROS (Robot Operating System) nedir?, <http://dusunenrobot.com/ros-robot-operating-system-nedir/>: [Mayıs].
- Kirk, D. E., Lim, L. Y. J. I. t. o. A. ve Systems, E., 1970, A dual-mode routing algorithm for an autonomous roving vehicle, (3), 290-294.
- Larochelle, H., Bengio, Y., Louradour, J. ve Lamblin, P. J. J. o. m. l. r., 2009, Exploring strategies for training deep neural networks, 10 (Jan), 1-40.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. J. P. o. t. I., 1998, Gradient-based learning applied to document recognition, 86 (11), 2278-2324.
- LeCun, Y., Bengio, Y. ve Hinton, G. J. n., 2015, Deep learning, 521 (7553), 436.
- Li, Q., Chen, L., Li, M., Shaw, S.-L. ve Nüchter, A. J. I. T. o. V. T., 2014, A sensor-fusion drivable-region and lane-detection system for autonomous vehicle navigation in challenging road scenarios, 63 (2), 540-555.
- Liu, D.-Y., Chen, H.-L., Yang, B., Lv, X.-E., Li, L.-N. ve Liu, J. J. J. o. m. s., 2012, Design of an enhanced fuzzy k-nearest neighbor classifier based computer aided diagnostic system for thyroid disease, 36 (5), 3243-3254.

- Luque-Baena, R. M., López-Rubio, E., Domínguez, E., Palomo, E. J. ve Jerez, J. M., 2013, A self-organizing map for traffic flow monitoring, *International Work-Conference on Artificial Neural Networks*, 458-466.
- Najva, N. ve Bijoy, K. E. J. P. C. S., 2016, Sift and tensor based object detection and classification in videos using deep neural networks, 93, 351-358.
- NVIDIACorporation, 2019a, <https://www.nvidia.com.tr/object/cuda-parallel-computing-tr.html>:
- NVIDIACorporation, 2019b, Convolutional Neural Network (CNN), <https://developer.nvidia.com/discover/convolutional-neural-network>:
- O'Kane, J. M., 2014, A gentle introduction to ROS.
- Özşahin, D., 2019, Yapay Zeka Tarihi, <http://dorukozsahin.com/yapay-zeka-tarihi/>: [Nisan].
- Particke, F., Kolbenschlag, R., Hiller, M., Patiño-Studencki, L. ve Thielecke, J., 2017, Deep Learning for Real-Time Capable Object Detection and Localization on Mobile Platforms, *IOP Conference Series: Materials Science and Engineering*, 012005.
- Plangi, S., Hadachi, A., Lind, A. ve Bensrhair, A. J. I. S. J., 2018, Real-Time Vehicles Tracking Based on Mobile Multi-Sensor Fusion, 18 (24), 10077-10084.
- ROS, About ROS, <http://www.ros.org/about-ros/>: [Şubat].
- Rubinstein, A. ve Erez, T., 2016, Autonomous robot for tunnel mapping, *2016 IEEE International Conference on the Science of Electrical Engineering (ICSEE)*, 1-4.
- Schmidhuber, J. J. N. n., 2015, Deep learning in neural networks: An overview, 61, 85-117.
- Siegwart, R., Nourbakhsh, I. R., Scaramuzza, D. ve Arkin, R. C., 2011, Introduction to autonomous mobile robots, MIT press, p.
- Suhr, J. ve Jung, H. J. E. L., 2018, Sensor fusion-based precise obstacle localisation for automatic parking systems, 54 (7), 445-447.
- Sun, Y., Su, T. ve Tu, Z., 2017, Faster R-CNN based autonomous navigation for vehicles in warehouse, *2017 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)*, 1639-1644.
- Tahboub, K., Güera, D., Reibman, A. R. ve Delp, E. J., 2017, Quality-adaptive deep learning for pedestrian detection, *2017 IEEE International Conference on Image Processing (ICIP)*, 4187-4191.

- Tomè, D., Monti, F., Baroffio, L., Bondi, L., Tagliasacchi, M. ve Tubaro, S. J. S. P. I. C., 2016, Deep convolutional neural networks for pedestrian detection, 47, 482-489.
- Toroslu, I. ve Doğan, M., 2018, Effective sensor fusion of a mobile robot for SLAM implementation, *2018 4th International Conference on Control, Automation and Robotics (ICCAR)*, 76-81.
- Trepagnier, P. G., Nagel, J. E., Kinney, P. M., Dooner, M. T., Wilson, B. M., Schneider Jr, C. R. ve Goeller, K. B., 2011, Navigation and control system for autonomous vehicles, Google Patents.
- Turing, A. M. J. M., 1950, Can a machine think, 59 (236), 433-460.
- Vancea, F. I., Costea, A. D. ve Nedeveschi, S., 2017, Vehicle taillight detection and tracking using deep learning and thresholding for candidate generation, *2017 13th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)*, 267-272.
- Wang, J.-G., Zhou, L., Pan, Y., Lee, S., Song, Z., Han, B. S. ve Saputra, V. B., 2016, Appearance-based brake-lights recognition using deep learning and vehicle detection, *2016 IEEE Intelligent Vehicles Symposium (IV)*, 815-820.
- Wang, Y., Zhang, L., Wang, L., Wang, Z. J. I. T. o. C. ve Systems, D., 2018, Multi-task Learning for Object Localization with Deep Reinforcement Learning.
- Wei, P., Cagle, L., Reza, T., Ball, J. ve Gafford, J. J. E., 2018, LiDAR and camera detection fusion in a real-time industrial multi-sensor collision avoidance system, 7 (6), 84.
- Wen, C., Qin, L., Zhu, Q., Wang, C., Li, J. J. I. G. ve Letters, R. S., 2014, Three-dimensional indoor mobile mapping with fusion of two-dimensional laser scanner and RGB-D camera data, 11 (4), 843-847.
- Xu, Q., Yang, Y., Zhang, C. ve Zhang, L. J. I. J. o. F. S., 2018, Deep convolutional neural network-based autonomous marine vehicle maneuver, 20 (2), 687-699.
- Yavuz, S., Amasyalı, M. F., Balcılar, M., Bilgin, G., Dinç, T. ve Kurt, Z. J. E., 2006, Eş Zamanlı Konum Belirleme ve Harita Oluşturma Amaçlı Otonom Bir Robot.
- Yoon, Y., Shin, J., Kim, H. J., Park, Y. ve Sastry, S. J. C. E. P., 2009, Model-predictive active steering and obstacle avoidance for autonomous ground vehicles, 17 (7), 741-750.
- Yu, J., Zhou, X. ve Qian, F., 2010, A novel approach for moving object detection based on improved particle swarm optimization algorithm, *IEEE ICCA 2010*, 1178-1183.
- Zhu, J., Montemerlo, M. S., Urmson, C. P. ve Chatham, A., 2012, Object detection and classification for autonomous vehicles, Google Patents.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Berat YILDIZ
Uyruğu : TC
Doğum Yeri ve Tarihi : Ağrı-1993
Telefon : 0555 009 79 67
Faks :
e-mail : Yildizberat2086@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Ortaklar Anadolu Öğretmen Lisesi, Germencik, AYDIN	2011
Üniversite	: Eskişehir Osmangazi Üniversitesi	2016
Yüksek Lisans	: Konya Teknik Üniversitesi	Devam ediyor
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2	Karamanoğlu Mehmetbey Üniversitesi	Arş. Gör.

UZMANLIK ALANI

Robotik, Yapay Zeka, Makine Öğrenmesi,

YABANCI DİLLER

İngilizce

YAYINLAR

Balci, S., Kayabasi, A. ve Yildiz, B. J. I. J. o. E., 2019, ANN Based Estimation of the Voltage Ripple According to the Load Variation of Battery Chargers, International Journal of Electronics (just-accepted).

Kayabasi, A., Yildiz, B., Sabanci, K., Yigit, E., Toktas, A. ve Tekbas, M., Ann-Based Classifier Trained By Bayesian Regularization For Wheat Grains Through Colour Feature.

Kayabasi, A., Yildiz, B., Aslan, M. F. ve Durdu, A., 2018, Comparison of ELM and ANN on EMG Signals Obtained for Control of Robotic-Hand, 2018 10th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), 1-5.

Kayabaşı, A. ve Yıldız, B. J. E., Design Of The Direct Current Motor Speed Controller With Embedded System Using Fuzzy Logic, 8 (2), 145-147.

Kayabaşı, A., Sabancı, K., Yiğit, E., Toktaş, A., Yerlikaya, M. ve Yıldız, B., 2017, Image processing based ann with Bayesian regularization learning algorithm for classification of wheat grains, 2017 10th International Conference on Electrical and Electronics Engineering (ELECO), 1166-1170

