



**UÇTAN UCA SÜRÜCÜSÜZ BİR ARACIN DERİN
ÖĞRENME MODELLERİ İLE KONTROL
EDİLMESİ**

Ali ART

**2022
YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Abdullah Talha SÖZER**

**UÇTAN UCA SÜRÜCÜSÜZ BİR ARACIN DERİN ÖĞRENME MODELLERİ
İLE KONTROL EDİLMESİ**

Ali ART

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğretim Üyesi Abdullah Talha SÖZER**

KARABÜK

Ocak 2022

Ali ART tarafından hazırlanan “UÇTAN UCA SÜRÜCÜSÜZ BİR ARACIN DERİN ÖĞRENME MODELLERİ İLE KONTROL EDİLMESİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğretim Üyesi Abdullah Talha SÖZER
Tez Danışmanı, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 06/01/2022

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Dr. Öğretim Üyesi Ferhat ATASOY (KBÜ)
Üye : Dr. Öğretim Üyesi Abdullah Talha SÖZER (KBÜ)
Üye : Dr. Öğretim Üyesi Emrah IRMAK (ALKÜ)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ
Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Ali ART

ÖZET

Yüksek Lisans Tezi

UÇTAN UCA SÜRÜCÜSÜZ BİR ARACIN DERİN ÖĞRENME MODELLERİ İLE KONTROL EDİLMESİ

Ali ART

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğretim Üyesi Abdullah Talha SÖZER

Ocak 2022, 57 sayfa

Sürücüsüz araç günümüzde hem akademi hem de endüstride popüler bir araştırma alanıdır. Sürücüsüz araç çalışmalarında öğrenme genel olarak geleneksel mimari yaklaşımı kullanılarak yapılmasına rağmen derin öğrenmedeki ve sensör teknolojisindeki ilerlemeler ile uçtan uca öğrenme mimarisi yaklaşımı da popüler bir araştırma konusu olmuştur. Uçtan uca öğrenme mimarisi geleneksel öğrenme mimarisinin aksine sensör verilerinin doğrudan kontrol komutlarına eşler. Sensör verilerinin direksiyon açısı, araç hızı ve fren gibi kontrol komutlarına doğrudan eşlenmesi derin öğrenme veya pekiştirmeli öğrenme gibi yöntemler kullanılarak yapılmaktadır. Bu çalışmanın amacı gerçek dünyadan toplanmış bir veri seti ile derin öğrenme temelli uçtan uca öğrenim metodundan faydalanan sürücüsüz aracın kontrol edilmesidir. Bu çalışmada şehir içi sürüşler esnasında toplanmış gerçek dünya verilerinden oluşan DBNET veri seti kullanılmıştır. Sürücüsüz araç farklı derin öğrenme modelleri kullanılarak uçtan uca eğitim mimarisi ile eğitilmiş ve test edilmiştir. Çalışma kapsamında öncelikle derin öğrenme modellerinde kullanılacak

kamera ve lidar verisi ile batch size boyutu belirlenmiştir. Sonrasında derin öğrenme modelleri ilk olarak sadece kamera verileri ile eğitilmiştir. Aynı eğitimler kamera ve lidar verileri ile tekrar gerçekleştirmiştir. Bu eğitimler sonucunda lidar verilerinin doğruluğa yaptığı olumlu katkı gözlemlenmiştir. Tahmin doğruluğunda kullandığımız tolerans değerinin eğitim esnasındaki etkisini incelemek için farklı derin öğrenme modelleri farklı tolerans değerleri ile eğitilip test edilmiştir. Ayrıca kullanılan derin öğrenme modelleri içinde uçtan uca öğrenme yönteminde en iyi sonuç veren model tespit edilmiştir. Son olarak ise off-road bir yolda kullanılan ikili semantik sınıflandırma yaklaşımının on-road bir yolda nasıl bir performans verdiği incelenmiştir.

Batch size boyutu olarak 32 değeri bu çalışma için uygun batch size boyutu olarak belirlenmiştir. 940x400 piksel kamera verileri ve 16384 noktalı lidar verileri bu çalışma için uygun veriler olarak belirlenmiştir. Pilotnet derin öğrenme modelinin kullanılan modelleri içinde en iyi öğrenen model olduğu gözlemlenmiştir. On-road yolda yapılan ikili semantik yaklaşımının bu çalışma için kötü sonuçlar verdiği tespit edilmiştir. Tüm eğitim ve test sonuçları farklı çizelge ve şekillerle tartışılmış ve yorumlanmıştır.

Anahtar Sözcükler : Sürücüsüz Araç, Otonom Araç, Derin Öğrenme, Uçtan Uca Öğrenme

Bilim Kodu : 92431

ABSTRACT

M. Sc. Thesis

CONTROLLING AN END-TO-END DRIVERLESS VEHICLE WITH DEEP LEARNING MODELS

Ali ART

Karabük University

The Institute of Graduate Studies

Department of Electrical-Electronics Engineering

Thesis Advisor:

Dr. Öğretim Üyesi Abdullah Talha SÖZER

January 2022, 57 pages

Today the driverless vehicle is a popular research area in both academia and industry. Although learning in driverless vehicle research is generally done using the traditional architecture approach, the end-to-end learning architecture approach has also become a popular research topic with advances in deep learning and sensor technology. The end-to-end learning architecture synchronizes sensor data directly to control commands, unlike traditional learning architecture. Direct synchronization of sensor data to control commands such as steering angle, vehicle speed and braking is done using methods such as deep learning or reinforcement learning. In this study, the DBNET dataset consisting of real world data collected during urban driving was used. The driverless vehicle has been trained and tested with an end-to-end training architecture using different deep learning models. In this study, first of all, camera and lidar data to be used in deep learning models and batch size were determined. Afterwards, deep learning models were first trained with only camera data. The same trainings were performed again with camera and lidar data. As a result of these trainings, the positive contribution of lidar data to accuracy was observed. Different

deep learning models were trained and tested with different tolerance values in order to examine the effect of the tolerance value we use on the prediction accuracy during training. In addition, among the deep learning models used, the model that gave the best results in the end-to-end learning method was determined. Finally, it is examined how the dual semantic classification approach used on off-road road performs on-road. For this study, the Batch size size was set to 32. 940x200 pixel camera data and 16384 point lidar data were determined as suitable data for this study. It has been observed that the Pilotnet deep learning model is the best learning model among the models used. In the semantic approach, it has been determined that the binary semantic approach on the on road gives bad results for this study. All training and test results are discussed and interpreted with different tables and figures.

Key Words : Driverless Vehicle, Autonomous Vehicle, End-to-End, Deep Learning

Science Code : 92431

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütölmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında şekillendiren sayın hocam Dr. Öğretim Üyesi Abdullah Talha SÖZER'e teşekkürlerimi sunarım.

Hayatım boyunca ve bu tez alıőmasında bana her türlü maddi ve manevi desteęi saęlayan annem, babam ve ablalarıma teşekkürlerimi sunarım.

Son olarak tez alıőmasında hem bir arkadaş olarak hemde bir akademisyen olarak desteklerini esirgemeyen her an bana maddi ve manevi yardımcı olan Yüksek Mühendis Semih Beyçimen kardeşime teşekkürlerimi sunarım.

İÇİNDEKİLER

Sayfa

KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	5
SÜRÜCÜSÜZ ARAÇ.....	5
BÖLÜM 3	14
MATERYAL & METOT.....	14
3.1. VERİ SETİ TESPİTİ.....	14
3.2. DERİN ÖĞRENME VE KULLANILAN METOTLARI.....	16
3.2.1. Resnet	19
3.2.2. Inception	20
3.2.3. DenseNet.....	22
3.2.4. PilotNet.....	23
3.3. VERİLERİN DÜZENLENMESİ.....	24
3.3.1. Kamera Görüntülerinin Kırılması.....	24
3.3.2. Lidar Sensör Verilerinin Filtrelenmesi	25
3.3.3. Sürücü Davranışları	27

	<u>Sayfa</u>
3.3.4. Kamera Görüntüsü Semantik Etiketlenmesi.....	28
3.4. DENEYLER.....	29
3.4.1. Deney A.....	29
3.4.2. Deney B.....	29
3.4.3. Deney C.....	30
3.4.4. Deney D.....	31
3.5. DEĞERLENDİRME KRİTERLERİ.....	31
BÖLÜM 4.....	33
DENEYSSEL SONUÇLAR.....	33
4.1. DENEY A.....	33
4.1.1. Batch size.....	34
4.1.2. Kamera Görüntüsü Kırılma Oranının Eğitime Etkisi.....	35
4.1.3. Farklı LİDAR Nokta Sayılarının Eğitime Katkısı.....	36
4.2. DENEY B.....	38
4.3. DENEY C.....	39
4.3.1. 3 Km/s ve 6 derece tolerans ile elde edilen sonuçlar.....	40
4.3.2. 5 km/s ve 6 derece tolerans ile elde edilen sonuçlar.....	44
4.4. DENEY D.....	49
BÖLÜM 5.....	50
SONUÇ VE ÖNERİLER.....	50
KAYNAKLAR.....	53
ÖZGEÇMİŞ.....	57

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1. Çalışma planı.....	2
Şekil 2.1. Sürücüsüz araç seviyeleri [15]'den alınarak düzenlenmiştir.	8
Şekil 2.2. Öğrenme mimarileri a) Geleneksel mimari, b) Uçtan uca mimari.....	9
Şekil 3.1. Yapay zekâ, makine öğrenmesi, derin öğrenme arasındaki ilişki.	16
Şekil 3.2. Derin öğrenme ve makine öğrenmesi [33]'den alınarak düzenlenmiştir..	17
Şekil 3.3. LeNet modeli.....	18
Şekil 3.4. Resnet modeli [38].	20
Şekil 3.5. Inception-V1 modeli [40].....	21
Şekil 3.6. Inception-v4 modeli [42].....	21
Şekil 3.7. Densenet modeli [45].	22
Şekil 3.8. PilotNet modeli modeli.	23
Şekil 3.9. Fazla kırpılmış – az kırpılmış kamera görüntüleri	25
Şekil 3.10. Lidar filtreleme.	26
Şekil 3.11. Sürücü davranışı dosyası.	27
Şekil 3.12. Semantik etiketleme.....	28
Şekil 3.13. Deney A tasarımı.	29
Şekil 3.14. Deney B-1 (sol) ve B-2 (sağ).....	30
Şekil 3.15. Deney C.	30
Şekil 3.16. Deney D.	31
Şekil 4.1. Deney A kapsamı.	33
Şekil 4.2. Farklı batch size değerleri için a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.	34
Şekil 4.3. Farklı kırpılmış kamera verileri eğitim sonuçları a) hız b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.	36
Şekil 4.4. Farklı Lidar nokta sayısı eğitim sonuçları a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.	37
Şekil 4.5. Deney B kapsamı.	38
Şekil 4.6. Deney C kapsamı.	39
Şekil 4.7. 6 derece açı – 3 Km/s hız tolerans eğitim sonuçları a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.	40

	<u>Sayfa</u>
Şekil 4.8. Düzenlenmiş homojen veri seti.....	41
Şekil 4.9. Tahmin – gerçek değer grafiği a) araç hızı b) direksiyon açısı.....	43
Şekil 4.10. 6 derece açı – 5 Km/s hız tolerans eğitim sonuçları a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.....	45
Şekil 4.11. Tahmin – gerçek değer a) araç hızı b) direksiyon açısı.	48
Şekil 4.12. Etiketli-etiketsiz karşılaştırma a) araç hızı b) direksiyon açısı.	49

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 3.1. Tolerans değerleri.	32
Çizelge 4.1. Deney B sonuçları.....	38
Çizelge 4.2. 3 Km/s ve 6 derece toleransa göre doğruluk sonuçları.	42
Çizelge 4.3. 3 Km/s ve 6 derece toleransa göre ortalama hata ve kayıp.....	44
Çizelge 4.4. 5 Km/s ve 6 derece tahmin doğruluğu sonuçları.	46
Çizelge 4.5. 5 Km/s ve 6 derece toleransa göre ortalama hata ve kayıp.....	47
Çizelge 5.1. Test sonuçları.	52

SİMGELER VE KISALTMALAR DİZİNİ

KISALTMALAR

CNN	: Convulation Neural Network (Evrışimli Sinir Ağı)
LSTM	: Long Short Term Memory (Uzun Kısa Süreli Bellek)
FCN	: Fully Convolutional Neural Networks (Tam Bağlı Evrışimli Sinir Ağı)
C-LSTM	: Convulation Long Short Term Memory (Evrışimli- Uzun kısa süreli Bellek)
YSA	: Yapay Sinir Ağları
DRL	: Deep Reinforcement Learning (Derin Pekiştirmeli Öğrenme)
LİDAR	: Light Detection and Ranging (Işık Tespiti ve Uzaklık Tayini)
IMU	: Inertial Measurement Unit (Atalet Ölçüm Birimi)
GPS	: Global Positioning System (Küresel Konumlama Sistemi)
DARPA	: Defense Advanced Research Projects Agency (Savunma İleri Araştırma Projeleri Ajansı)
ELROB	: The European Land Robot Trial (Avrupa Kara-Robot Denemesi)
GCDC	: Grand Cooperative Driving Challenge (Büyük Kooperatif Sürüş Yarışması)
SAE	: Society of Automobile Engineers (Otomobil Mühendisleri Derneği)
ALVINN	: Autonomous Land Vehicle in a Neural Network (Sinir Ağında Otonom Kara Aracı)
DAVE	: Darpa Autonomous Vehicle (Darpa Otonom Aracı)
TORCS	: The Open Racing Car Simulator (Açık Araba Yarışı Simülatörü)
A3C	: Asynchronous Advantage Actor-Critic (Asenkron Avantaj Oyuncu-Eleştirmen)

BÖLÜM 1

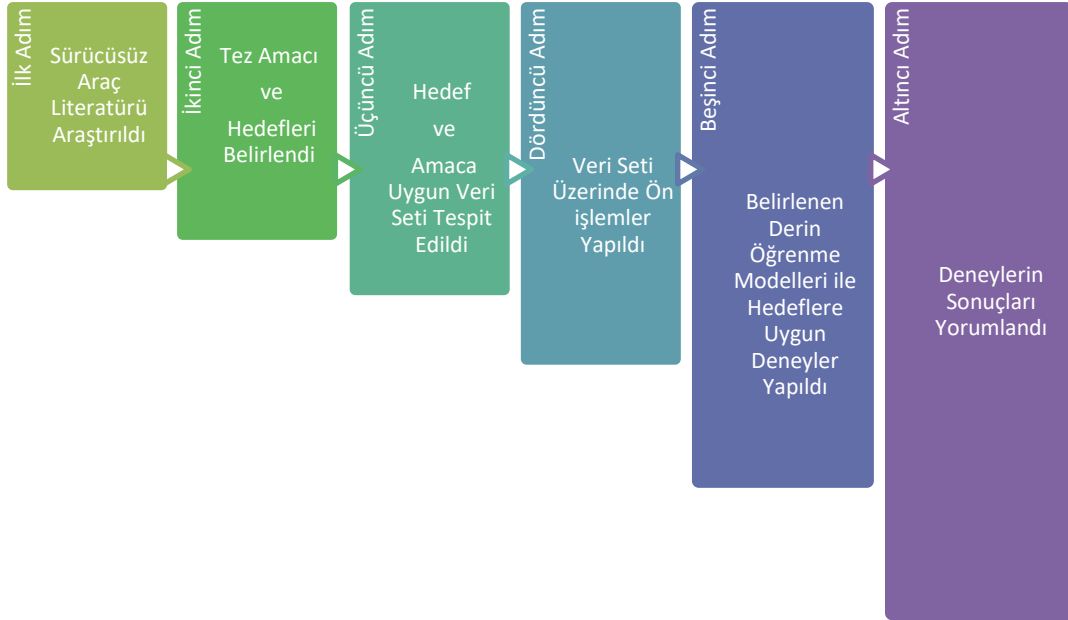
GİRİŞ

Fabrika ortamları gibi yapılandırılmış, çalışabilmesi için uyarlanmış, ortamlarda faaliyet gösteren robotik teknolojiler, son yıllarda tarım, sağlık, madencilik, uzay araştırmaları ve sürücüsüz araçlar gibi yapılandırılmamış ortamlarda da kullanılmaya başlanmış ve yeni bir döneme girmiştir. Bu robot teknolojilerinin bir kolu olan sürücüsüz araçlar üzerine son yıllarda birçok çalışma yapılmaktadır. Bu yapılan çalışmalarda, özellikle son on yılda derin öğrenme ve yapay zekâ alanındaki gelişmelerin öncülüğünde, giderek daha hızlı bir ilerleme kaydedildiği görülmektedir. Derin öğrenme ve yapay zekâ, sürücüsüz bir aracın algılama, planlama ve kontrol aşamalarının her bir aşamasındaki problemlere uyarlanarak kullanıldığı gibi; sürücüsüz araç sensör verilerindeki bilgileri, frenleme, dönme gibi yönlendirme komutlarına doğrudan eşleyebilen, yeni bir yaklaşım olan ve gelişimi devam eden uçtan uca öğrenme yönteminde de kullanılmaktadır. Günümüzde, derin öğrenme temelli sürücüsüz araç çalışmalarının büyük bir çoğunluğu, esas olarak uçtan uca öğrenme yöntemlerine odaklanmaktadır [1].

İnsan davranışına daha benzer görünen uçtan uca öğrenme metodu, yapılandırılmamış bir ortamdaki sürüş için alternatif bir yöntem olarak son zamanlarda araştırmacılar için cezbedici bir konu olmuştur. Uçtan uca öğrenme metodunda, bir insan nasıl ki göz, kulak, burun gibi duyuşsal algılayıcılar ile topladığı veriler yardımıyla çevresini anlamlandırıyor; duyuşsal algılayıcılara benzeyen kamera, “Light Detection and Ranging” (lidar), “Inertial Measurement Unit” (IMU), “Global Positioning System” (GPS) gibi endüstriyel algılayıcılar vasıtasıyla toplanan ham veriler yönlendirme komutlarına doğrudan eşlenerek sürücüsüz aracın çevresini anlamlandırması amaçlanmıştır. Uçtan uca öğrenme metodunda birkaç istisna çalışma hariç derin öğrenme kullanılmaktadır [2]. Derin öğrenme modelleri büyük eğitim veri setlerine ihtiyaç duyar ve güçlü hesaplama donanımı gerektirir. Bu

nedenle derin öğrenme yöntemlerinin kullanıldığı alanlarda modelin eğitiminde gereken zaman ve enerji ihtiyacının azaltılabilmesi için optimum veri ve uygun derin öğrenme modelinin tespitini önemli kılmaktadır.

Bu çalışmanın amacı kapsamında, belirlenen bir veri seti üzerinde derin öğrenme temelli uçtan uca öğrenim metodundan faydalanan sürücüsüz araç farklı derin öğrenme modelleriyle eğitilerek kontrol edilmiştir. Ayrıca aynı veri setinde farklı derin öğrenme modelleri kullanılarak uçtan uca öğrenim için seçilen modellerin arasından en uygun model tespit edilmiştir. Çalışma planı Şekil 1.1’de görülmektedir.



Şekil 1.1. Çalışma planı.

Tezdeki amacı gerçekleştirilebilmek doğrultusunda dört hedef belirlenmiştir.

1. İlk hedefte diğer üç hedefte kullanılacak batch size boyutu ile kamera ve lidar verileri belirlendi. İlk hedef kapsamında öncelikle eğitimler 8,16,32 batch size boyutları ile gerçekleştirildi. Daha sonra 1280x1080 pikseli ham kamera verisine iki farklı kırpma işlemi uygulandı. Bu kırpma işlemleri sonucunda sırasıyla 1080x600 ve 940x400 pikseli iki farklı kırpılmış kamera verisi oluşturuldu. Bu iki farklı kırpılmış kamera verileriyle eğitimler yapıldı. Bu

çalışma için bu iki kırılmış veri arasındaki uygun boyutlu kamera verisi tespit edildi. İlk hedefin son aşamasında ise her bir senaryosunda 700000 nokta bulunan lidar verisine önce SOR filtresi uygulandı. SOR filtresi uygulandıktan sonra her bir lidar sahnesinden Cloud Compare programı ile rastgele sırasıyla 16384 ve 32768 nokta seçildi. Bu iki farklı nokta sayısı ile eğitimler yapıldı. Bu çalışma için bu iki eğitimden uygun olan nokta sayısı tespit edildi. Yukarıdaki deneylerin sonucunda batch size boyutu 32, 940x400 boyutlu daha fazla kırılmış kamera verileri ve 16384 noktalı lidar verilerinin sonraki hedefler için uygun olduğuna karar verildi.

2. İkinci hedefte lidar verisinin öğrenmeye etkisini gözlemek için sadece kamera verileri ile eğitilmiş derin öğrenme modelleri ve hem kamera hem de lidar verileri ile eğitilmiş derin öğrenme modelleri karşılaştırılmıştır. Inception-V4, Resnet-152, PilotNet ve Densenet-169 derin öğrenme modelleri kullanılmış ve tüm ağlarda hem kamera hemde lidar verileri ile eğitilmiş derin öğrenme modellerinin daha iyi öğrenme sonuçları verdiği gözlemlenmiştir.
3. Üçüncü hedefte toleransın öğrenmeye etkisi araştırılmıştır. Bu kapsamda derin öğrenme modellerinde farklı tolerans değerlerinin eğitim aşamasındaki etkisini gözlemlenmiştir. Değişen toleransın hem eğitim sonuçları hem de test sonuçlarını etkilediği gözlemlenmiştir.
4. Dördüncü hedef kapsamında kamera görüntülerinin etiketlenmesinin öğrenmeye etkisi gözlemlenmiştir. Böylece literatürde daha önce off-road yol için denenilen [3] semantik yaklaşımın kent senaryosunda nasıl performans verdiği değerlendirilmiştir. Sonuç olarak off-road için uygulanan semantik yaklaşım on-road bir yolda performansı olumsuz etkilediği gösterdiği tespit edilmiştir.

Bu tez aşağıda içeriği özetlenen gibi beş bölümden oluşmaktadır.

1. GİRİŞ: Bu bölümde tezin konusu, amacı ve hedefleri belirtilmiştir. Tez çalışması kapsamında uygulanan deneylerden ve elde edilen sonuçlardan kısaca bahsedilmiştir.

2. SÜRÜCÜSÜZ ARAÇ: Bu bölümde sürücüsüz araçların tarihçesi verilmiştir. Sürücüsüz araç yaklaşımları açıklanmıştır. Geleneksel bir sürücüsüz araç mimarisi ile uçtan uca öğrenme mimarisi karşılaştırılmıştır. Uçtan uca öğrenme yaklaşımının literatür taraması sunulmuştur.
3. MATERYAL & METOT: Bu bölümde tez sürecinde kullanılan tüm materyal, metot ve tasarlanan deneyler verilmiştir. Kullanılan veri seti, derin öğrenme metodu, kullanılan derin öğrenme modelleri, sensörlerden elde edilen verilerin ön işleme tabi tutulması, eğitim başarı kriteri geniş bir şekilde anlatılmıştır.
4. DENEYSEL ÇIKTILAR VE YORUMLANMASI: Bu bölümde gerçekleştirilen deneylerin çıktıları grafik ve tablolar ile görselleştirilmiştir ve tartışılmıştır.
5. SONUÇ: Bu bölümde çalışmaların neticesinde ulaşılan sonuçlar açıklanmış ve gelecek çalışmalar için öneriler sunulmuştur.

BÖLÜM 2

SÜRÜCÜSÜZ ARAÇ

Sürücüsüz araç fikri 1920'li yıllarda doğmasına rağmen 1980'li yıllara kadar sürücüsüz araç teknolojisinin uygulanabileceğine olan inanç çok düşüktü[4].1980'li yıllarda Ernst Dickmanns [5] liderliğindeki öncü çalışmalar, sürücüsüz araçların uygulanabilirliğine olan inancı yükseltti. Ernst Dickmanns liderliğindeki ekip tarafından yürütülen Prometheus projesi, sürücüsüz bir araç geliştirmek için finanse edilen büyük bir projeydi. Yapılan bu çalışmalardan sonra 1980'li yılların ortalarından itibaren sürücüsüz araç dünya çapında birçok üniversite, araştırma merkezi, otomobil sektörü ve diğer endüstri şirketleri için cezbedici bir konu oldu [6]. 1994 yılında Vamp sürücüsüz aracı 1600 kilometreyi %95 otonom sürüş ile kat ederek çalışmalarda kayda değer bir ilerleme olduğunu gösterdi [7].1995 yılında ise CMU NAVLAB sürücüsüz aracı 5000 kilometreyi %98 otonom sürüş ile kat ederek sürücüsüz araç çalışmalarını 1994 yılında gelinen noktadan daha ileri bir noktaya götürdü [6]. Takip eden yıllarda “Defense Advanced Research Projects Agency” (DARPA) bu konuda üç yarışma düzenledi. Bu yarışmalarının ilki olan DARPA müsabakası, 2004 yılında ABD'nin Mojave Çölü'nde gerçekleştirildi. Bu müsabakada 142 mil uzunluğa sahip bir rota belirlenmiş ve bu rotanın tamamlanması için bir zaman sınırı konulmuştu. DARPA yarışmasına 15 araç katıldı ancak katılan 15 araçtan hiçbiri bu yarışmayı tamamlayamadı. 2005 yılında ise DARPA 2004 yılındakine benzer bir yarışma daha düzenledi. 2005'teki DARPA müsabakasında, güzergah üç dar tünel ve 100'den fazla keskin sola ve sağa dönüş bulunan daireler, kuru göl yatakları ve dağ geçitlerinden geçen 132 mil uzunluğundaki bir rotadan oluşturuldu. Yarışmada katılımcıların görevi tamamlayabilmesi için zaman sınırı bulunmaktaydı. Bu yarışmada 25 finalistten sadece 4'ü yarışmayı tamamlayabildi. 2007 yılında ise DARPA Kent olarak bilinen üçüncü yarışma düzenlendi. Günlük trafikte karşılaşılanlardan çok daha basit zorluklar sunulan ve trafik kurallarına uyularak sürülmesi gereken 60 millik rotada düzenlenen bu yarışmada 11 finalistten

6'sı yarışmayı tamamlayabildi [6]. DARPA müsabakaları bu alanda yapılan tek yarışmalar değildir, DARPA gibi birçok sürücüsüz araç yarışmaları ve denemeleri yapılmıştır ve yapılmaya devam etmektedir. 2006'dan bu yana devam etmekte olan "The European Land Robot Trial" (ELROB) [8], 2009 yılından 2013 yılına kadar devam eden "Intelligent Vehicle Future" müsabakası [6], 2009 yılından 2017 yılına kadar devam eden kadar Sparkfun Otonom Araç Yarışması [9], 2010 yılındaki Hyundai Otonom araç müsabakası [10] yine 2010 yılında düzenlenen VisLab Kıtalararası Otonom müsabakası [11], 2011 ve 2016 yıllarında düzenlenen "Grand Cooperative Driving Challenge" (GCDC) [12] bu yarışmaların bilinen başlıca örnekleridir.

Son zamanlarda özellikle derin öğrenme ve yapay zekâ alanındaki gelişmeler ve büyük veri setlerinin daha hızlı ve verimli bir şekilde işlenmesini sağlayan donanımsal ilerlemelerin de katkılarıyla dünya genelinde akademi ve endüstride sürücüsüz araçlar üzerine yapılan araştırmalarda hızlanma görülmektedir. Sürücüsüz araç üzerine akademik araştırmalar yapan Stanford Üniversitesi, Carnegie Mellon Üniversitesi, MIT, Virginia Tech, FZI Bilgi Teknolojileri Araştırma Merkezi ve Ulm Üniversitesi bu alanda öncülük yapan üniversitelerdir. Bunların arasında Carnegie Mellon üniversitesi sürücüsüz araç çalışmalarının merkezi olarak kabul edilebilir. Bu üniversite 30 yılı aşkın süredir, sürücüsüz araçlar için yenilikçi bir araştırma merkezi olmuştur. 1989 yılında uçtan uca öğrenme metodu ile yapılan Alvin'n çalışması, Carnegie Mellon üniversitesine aittir [13]. Bir başka örnek ise Stanford üniversitesi otonom araç takımının 2005 yılındaki DARPA Grand müsabakasını kazanmasıdır. Sürücüsüz araç üzerine endüstriyel araştırma yapan Google, Uber, Baidu, Tesla, Nvidia, Bosch, Argo AI, Almotive, AutoX, Toyota, Ford, Volvo ve Mercedes Benz şirketleri endüstride bu alanda öncülük yapan şirketlerdir [6]. Sürücüsüz araç konusunda endüstriyel araştırma yapan bu öncü şirketlerden biri olan TESLA, günümüzde sürücüsüz araç teknolojisi geliştiren ve geliştirdiği teknolojiler ile seri üretim yapan ilk şirkettir. Oto pilot sistemi uygulamalarında açık ara en başarılı şirketlerden biri olan Tesla, Model S adındaki oto pilot teknolojisini 2014 yılında piyasaya sürmüştür. TESLA'nın bu oto pilot teknolojisi, sürücüsüz aracın nihai hedefinden uzak olmasına rağmen, TESLA oto pilot sistemiyle bu alanda çalışma yapan araştırmacılara ve şirketlere bir otomobilin temel olarak belirli koşullar altında

otomatik sürüş gerçekleştirebildiğini göstermiştir. Bu öncü şirketlerden bir başka şirket olan Google, 2015 yılında sürücüsüz aracının performansını gerçek hayat ortamında test etti ve bu sürücüsüz araç şimdiye kadar 3,2 milyon km'den fazla yol yaparak test edilen gerçek kullanıma en yakın olan sürücüsüz araç oldu. Sürücüsüz araç konusunda endüstriyel olarak İsveç'te VOLVO ve AUTOLİV, sürücüsüz araç güvenliğini taahhüt eden ortak bir şirket olan ZENUİTY'yi kurdu. Güney Kore'de SAMSUNG, sürücüsüz arabalarını 2017 yılında halka açık yollarda test etmek için Güney Kore hükümetinden onay aldı. SAMSUNG şirketinin 2011 yılından 2017 yılına kadar sürücüsüz araç alanında dünyada en fazla patent başvurusunda bulunan şirket olduğu belirtilmektedir. Çin'de, BAİDU derin öğrenme enstitüsü, 2013 yılında sürücüsüz araç araştırma projesine öncülük etti. 2014 yılında BAİDU, otomotiv ağı iş bölümünü kurdu ve art arda CARLİFE, MY-CAR, CODRİVER gibi ürünleri piyasaya sürdü [14].

Günümüzde otomobil endüstrisi, sürücüsüz araçları farklı özelliklere sahip sürücü asistan seviyeleri ile tanımlamaktadır. Bu seviyeler aracı, sürücünün tam yetkili olmasından sürücünün hiçbir bir etkisi olmamasına kadar aşamalı bir şekilde seviyelere ayırmaktadır. Sürücüsüz araçlar “Society of Automobile Engineers” (SAE) tarafından seviye 0'dan seviye 5'e kadar altı farkı seviyede kategorize edilmektedir (Şekil 2.1).

Tüm sorumluluğun sürücüde olduğu ve herhangi bir sürüş otomasyonunun bulunmadığı seviye sıfırda sadece ABS fren ve seyahat sırasındaki kör nokta uyarısı gibi sadece anlık uyarılar bulunabilmektedir. Bunlar günümüzdeki birçok araçta temel olarak bulunan seviyelerdir. Aracın direksiyon kontrolünden gaz ve fren pedalı kontrolüne kadar her şeyi sürücünün yapması gerekmektedir. Birinci seviyede yine sürüş sırasında tüm sorumluluk sürücüye aittir. Bu seviyede belirli trafik koşullarında sürücüye yardımcı olacak, bazı özellikler bulunabilir. Bu seviyede sürücü her zaman direksiyonu tutmak zorunda değildir, araç şerit ortalama özelliği ile direksiyon kontrolünü veya hız sabitleyicisi ile hızını kendi ayarlayabilir, fakat bu özellikler birbirleriyle senkronize bir şekilde çalışmaz.



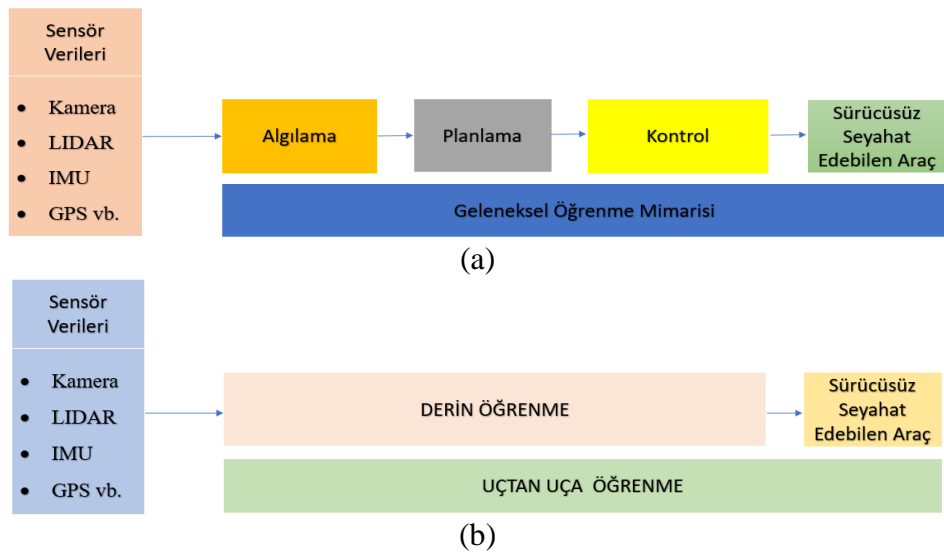
Şekil 2.1. Sürücüsüz araç seviyeleri [15]'den alınarak düzenlenmiştir.

İkinci seviyede ise birinci seviyede belirttiğimiz otomatik özellikler eş zamanlı bir şekilde çalışabilir. Örneğin bu seviyede adaptif araç hız sabitleyicisi ve şerit ortalama özellikli direksiyon kontrolü beraber eş zamanlı olarak otomatik bir şekilde çalışabilir. Bu eş zamanlı çalışma sonucunda sürücünün gözünün yola bakması gerekliliği ortadan kalkmaktadır. Ancak bu seviyede de sürüş sırasındaki tüm sorumluluk yine sürücüye aittir. Sürücü gerektiği takdirde sürüşe müdahale etmektedir. Üçüncü seviye sürücüsüz araç tanımının değiştiği bir seviyedir. Sürücüsüz araç sistemindeki algılayıcılar sayesinde seyahat ettiği çevreyi algılama yeteneğine sahiptir. Bu seviyede araç algıladığı çevrenin şartlarına göre kendisi karar verilebilir. Örneğin aracın önünde yavaş giden bir başka araç varsa sürücüsüz araç öndeki aracı kendi karar mekanizması ile hızlanarak geçebilir. Sürücü bu seviyede tüm kontrol yetkisini sisteme verir, fakat herhangi bir arıza durumunda veya orman yolunda önüne aniden hayvan çıkması gibi hiç karşılaşmadığı anlık bir senaryoda sistemin kontrolünü geri almak için seyahat görevi esnasında araçta hazır bulunmak zorundadır. Dördüncü seviyede bir önceki seviyenin tüm özelliklerini barındırmakla beraber bir önceki seviyeden en büyük farkı sürüş sırasında sürücünün araçta bulunması isteğe bağlıdır. Yani araç istenmeyen bir durumda otomatik sürüş özelliği ile anlık senaryolarda dahi olaya müdahale edebilir. Bu seviyede bazı firmalar günümüzde test çalışmalarında bulunmaktadır. Günümüzde henüz güvenlik şartları ve hukuksal mevzuatlar tam olarak gelişmediği için belli hız sınırları ile belli alanlarda dördüncü seviye sürücüsüz araç kullanılabilir. Bu seviyede gaz

pedalı ve direksiyon bulunması opsiyoneldir. Robot taksiler bu seviyeye örnek verilebilir. Beşinci seviye ise hiçbir şekilde bir insan müdahalesine imkân tanımayan tam bir sürücüsüz araçtır. Bu seviyede direksiyon, gaz, pedalı bulunmaz; araç tamamen sahip olduğu algılayıcılar tarafından kontrol edilir. Bu seviyedeki sürücüsüz araçlar dünyanın çeşitli yerlerine testlerden geçmektedir, ancak hiçbiri henüz halka açık trafiğe sunulmamıştır. Günümüzde beşinci seviye bir sürücüsüz aracın yollarda görülmesine hem teknik hem de yasal düzenlemeler nedeniyle uzun yıllar olduğu söylenebilir.

Sürücüsüz araç araştırmaları, SAE'nin belirlemiş olduğu seviyelerde açıklandığı gibi aracın direksiyon açısını belirleme, hız kontrolü, etraftaki nesnelerin hareketlerini değerlendirerek kazalardan kaçınma gibi sürüş görevlerinin hepsini mümkün olduğunca sürücü sorumluluğundan kurtarıp otomatikleştirmeyi amaçlar. Sürücüsüz araç çalışmalarında bu amacı gerçekleştirebilmek için geleneksel mimari ve uçtan uca öğrenme mimarisi olmak üzere iki farklı mimari kullanılmaktadır.

Şekil 2.2'de gösterilen geleneksel sürücüsüz araçlar genel olarak algılama, planlama, kontrol aşamalarından oluşan bir çalışma prensibine sahiptir. Bu çalışma prensibinde algılama, planlama, kontrol bloklarının her birinde sürücüsüz aracın doğru çalışması için farklı görevler yapılmaktadır. Bu şekilde çalışan bir sürücüsüz araç öğrenme metoduna geleneksel öğrenme mimarisi denilmektedir.



Şekil 2.2. Öğrenme mimarileri a) Geleneksel mimari, b) Uçtan uca mimari.

Geleneksel öğrenme mimarisine sahip sürücüsüz araçlarda sensörlerden toplanan veriler sırasıyla algılama, planlama ve kontrol katman aşamalarından geçerek sürücüsüz araç için en doğru kontrol komutları ve navigasyon sağlayarak seyahatin güvenli bir şekilde tamamlanması sağlanmaktadır. Bu mimarinin ilk aşaması algılama aşamasıdır. Bu aşamada araç çevresindeki araba, trafik işareti, üzerinde seyahat ettiği yolun özellikleri (asfalt, taş, toprak yol vb.) ve yaya veya sokak hayvanları gibi canlı nesnelere tanır. Algılama aşamasında aracın o anki konumu da belirlenir, ayrıca sürücüsüz seyahat edebilen araç konusunun en zor problemlerinden olan etrafında nesnelere ilerleyen saniyelerde nasıl davranış yapabileceği ile ilgili bir tahmin yürütür. Örneğin etrafındaki bir arabanın birkaç saniye sonra şerit değiştirip değiştirmeyeceği veya önündeki bir yayanın davranışının ne olabileceğini tahmin etmeye çalışır. Algılama aşamasında bahsedilen görevleri yapabilmek için kamera, radar, lidar, sonar, GPS, IMU gibi sensörlerden gelen büyük miktardaki verileri kullanır. Sürücüsüz aracın geleneksel öğrenme mimarisinde algılama ve karar verme hiyerarşisinde ikinci aşama ise planlama aşamasıdır. Bu aşamada sürücüsüz aracın ulaşmak istediği konuma ulaştıracak bir görev planlanır. Görev planlandıktan sonra bu göreve uygun yol planlaması yapılır. Son aşama ise kontrol aşamasıdır. Kontrol aşamasında planlanan görevi gerçekleştirmek için gerekli direksiyon açısı, araç hızı gibi değerler tahmin edilir ve aracın planlanan görevi hatasız bir şekilde tamamlaması kontrol algoritmalarıyla sağlanır.

Bir diğer öğrenme metodu uçtan uca öğrenme mimarisidir. Geleneksel öğrenme mimarisinden farklı olarak uçtan uca öğrenme mimarisi algı, planlama ve kontrol bloklarını tek blokta birleştirir. Bu birleştirilen blokta derin öğrenme tekniklerinin yardımıyla araç kontrol komutları elde edilir ve sürücüsüz aracın güvenli seyahat etme görevi yerine getirilir. Uçtan uca öğrenme, bir sinir ağına sensörler tarafından toplanan girdileri eğitmekte ve ağ çıktısı olarak direksiyon açısı ve araç hızı gibi kontrol komutları üretmektedir. Uçtan uca öğrenme mimarisi büyük verilere ve bu büyük verileri sağlıklı, doğru bir şekilde işleyip değerlendirebilecek gelişmiş donanım ve algoritmalara ihtiyaç duyan bir öğrenme metodudur. Daha az veri ile öğrenme yapabilen geleneksel makine öğrenmesi teknikleri uçtan uca öğrenme için çok verimli öğrenme teknikleri değildir ve bu nedenlerden ötürü literatürde birkaç örnek dışında [16,17] geleneksel makine öğrenmesi metodları uçtan uca öğrenme

yöntemi için kullanılmamaktadır. 1990'lı yıllardaki, adını “Autonomous Land Vehicle in a Neural Network” yani adını bir sinir ağında otonom kara aracı anlamına gelen kelimelerinin baş harflerinden alan ALVINN adlı çalışma geleneksel makine öğrenmesi ile yapılan uçtan uca öğrenme için bir örnek çalışmadır. Bu çalışmada araç önceden tanımlanmış bir yolu takip edecek ve gözlemlenen yolun eğriliğine göre yönlenebilecek şekilde tasarlanmıştır. 3 katmanlı bir sinir ağında eğitimler yapılmıştır. Sürüş ortamı verileri ise kamera ve lazer mesafe ölçer sensörleri tarafından elde edilmiştir [18].

2006 yılındaki çalışmada, birkaç araştırmacı tarafından tasarlanan “Darpa Autonomous Vehicle” (DAVE) mobil robotu benzer ancak aynı olmayan sürüş senaryolarında saatlerce insan tarafından sürülerek ham kamera verileri toplanmıştır. Toplanan ham kamera verileri 6 katmanlı bir evrişimli sinir ağı ile eğitilmiştir. Eğitimden sonra ise mobil robot engellerle dolu bir yoldan geçmeyi başarmıştır. [16].

Son zamanlarda özellikle derin öğrenme ve yapay zekanın gelişimi büyük verilerin işlenmesini verimli bir hale getirmiştir. Bu sebeple derin öğrenme temelli uçtan uca öğrenme yaklaşımının popülerliği artmaktadır. Derin öğrenme kullanılarak, uçtan uca öğrenme metoduyla birçok çalışma yayınlanmıştır. Uçtan uca öğrenme metodunda 2017 yılında Nvidia şirketi tarafından geliştirilen Pilotnet modeli ile gelişmeler görüldü. Bu çalışmada bir ön kameradan gelen ham kamera verilerini doğrudan yönlendirme komutlarına eşleyen bir “Convolutional Neural Network” “(CNN)” eğitilmiştir. Eğitim verileri, çeşitli aydınlatma koşullarında, çeşitli hava koşullarında ve ayrıca farklı yol türlerinde gerçekleştirilen sürüşlerle toplanan görüntüler ve direksiyon komutlarından oluşturulmuştur. [19]. 2017 yılındaki yapılan başka bir çalışmada büyük boyutlu video veri setlerinden alınan verilerle kapsamlı model tasarlanmıştır. Bu çalışmada uçtan uca eğitilebilir bir tam evrişimli sinir ağı “Fully Convolutional Network” ile “Long–Short-Term Memory” (FCN-LSTM) yöntemi mimarisi geliştirmiştir [20]. 2017 yılındaki bir diğer çalışmada araştırmacılar o zamana kadar yapılan çoğu araştırmada yalnızca görsel kamera çerçevelerinin girdi olarak kabul edildiğini, bunun ise sürüş çerçeveleri arasındaki zamansal ilişkiyi göz ardı ettiğini ileri sürmüştür. İddia ettikleri bu problemi çözmek için çalışmalarında sürüşün hem görsel hem de dinamik zamansal bağımlılıklarını

dikkate almak için uçtan uca eğitilebilir bir “Convolutional Long–Short-Term Memory” (C-LSTM) tasarlamışlardır. Girdi olarak kameradan alınan görüntü çerçeveleri ve aracın tekerlek açısı kullanılmıştır [21]. 2017 yılında uçtan uca öğrenme metoduyla evrişimli sinir ağı kullanılarak yapılan bir başka çalışmada “The Open Racing Car Simulator” (TORCS) kullanarak geniş bir veri seti toplanmış ve görüntü özellikleri gökyüzüyle, yol kenarıyla ve yolla ilgili özellikler olarak üç kategoride sınıflandırılmıştır. Kurulan modellerle araştırmacılar bu özelliklerin her birinin uçtan uca öğrenme üzerindeki etkisini tespit etmiştir. Torcs simülasyon resimleri eğitim verisi olarak kullanılmıştır [22]. 2018 yılında yapılan çalışmada uçtan uca öğrenme için çevresel görüş kameraları kullanılması önerilmiştir. Çalışmada sürücülerin güvenli sürüş için dik ve yan aynalara sahip olması ve dik ve yan aynaların sayesinde bir sürücünün arabanın etrafında neler olup bittiğine dair daha eksiksiz bir görüntü elde ettiği belirtilmiştir. Bu nedenden dolayı sürücüsüz araç içinde algılayıcı görevi yapan kamera yerleşim tasarımı 360 derece her açıyı görecektir şekilde ayarlanmıştır. Bunun için 8 kamera kullanılmıştır. Uçtan uca öğrenme metodunda CNN ve tam FCN-LSTM modellerinden yararlanılmış ve çıktı olarak direksiyon açısı ve hız kontrol değerleri elde edilmiştir [23]. 2018 yılındaki diğer bir çalışmada “Asynchronous Advantage Actor-Critic” (A3C) yaklaşımına dayalı bir “Deep Reinforcement Learning” (DRL) yöntemi benimsenmiştir. A3C mimari ağı, derinlik görüntüsünü, yükseklik haritasını ve robot oryantasyonunu üç farklı dalda, evrişimli katmanlar ve tam bağlantılı katmanlar aracılığıyla işlemiştir. Ağın eğitimi, 4 tekerlekli mobil platformun dinamik modeli ile simülasyonda gerçekleştirilmiştir. Ağdan çıktı olarak ise direksiyon açısı elde edilmiştir [24]. 2019 yılında yapılan bir tarım robotu çalışmasında sadece büyük bir ormana ait kamera görüntüleri kullanılarak direksiyon açısı tahmin edilen bir yaklaşım sunulmuştur. Bu yaklaşımda araştırmacılar derin bir evrişimli sinir ağı ile uçtan uca öğrenme yöntemini kullanmışlardır [25]. 2020 yılında yapılan çalışmada, çökmüş alanlar veya doğal mağaralar gibi karmaşık ortamlarda otonom navigasyon sorununu ele almak için çok girişli bir füzyon yaklaşımı önerilmiştir. Araştırmacılar simülasyon ortamında tasarladıkları karmaşık ortamda öğrenme için gerekli veri setini toplamışlardır. Bu veri setinde lazer mesafe ölçen, kamera ve nokta bulutu algılayıcılarından toplanan veriler birleştiren yeni bir öğrenme bir mimarisi önermiştir [26]. 2020 yılında yapılan çalışmada veriler JACKAL adlı araştırma robotu kullanılarak toplanmıştır. Bir

evrişimli sinir ađı ile uçtan uca öğrenme metodu kullanılarak, açısai ve doğrusal hız kontrol komutları tahmin edilen bir model geliştirilmiştir. Evrişimli sinir ađına kamera görüntüleri girdi olarak verilmiştir [27].

Sürücüsüz araçlar günümüzde hem endüstride hemde akademide farklı öğrenme yöntemleri kullanılarak araştırılmaya devam edilmektedir. Seviye 5 'e ulaşma hayaliyle yapılan bu çalışmalar belirli bir seviyeye gelmiş olsa da istenilen seviyenin halen çok gerisindedir. Bu nedenle bu konuda çözülmesi gereken birçok problem ve atılması gereken birçok adım vardır.

BÖLÜM 3

MATERYAL & METOT

Bu çalışmada uçtan uca öğrenme metodundan faydalanarak bir sürücüsüz aracın eğitilmesi ve eğitilen modelin değerlendirilmesi yapılmıştır. Sürücüsüz araç eğitilirken farklı kamera ve lidar sensör verileri kullanılmıştır. Dört farklı deney oluşturulmuştur.

Bu bölümde uçtan uca öğrenme metoduyla öğrenen bir sürücüsüz aracın eğitim performansını artırmak için kullanılan araçlar ve uygulanan yaklaşımlar detaylı bir şekilde açıklanmıştır. Yoğun trafiğin var olduğu kent senaryosunda sürücü davranışı ve araçtaki sensörler ile toplanan veriler farklı yaklaşımlar ile değerlendirilerek yüksek doğruluk elde edilen bir uçtan uca öğrenme gerçekleştirilmiştir. Kullanılan araçlar ve uygulanan yaklaşımlar sırasıyla veri seti tespiti, kullanılan derin öğrenme modelleri, verilerin düzenlenmesi, deneyler ve değerlendirme kriterleri alt başlıklarında açıklanacaktır.

3.1. VERİ SETİ TESPİTİ

Büyük veri setleri, öğrenmede büyük boyutlu verilere ihtiyaç duyan derin öğrenme gelişimine büyük katkı sağlamıştır. Çalışmada, sürücüsüz aracın eğitimi ile yönlendirme komutlarının tahmini hedeflendiği için, kullanılacak veri setinde en önemli kriter etiketlenmiş sürücü davranışlarının bulunmasıdır. Yine hedeflenen çalışmanın gerçek hayata uygulanabilirliğini arttırabilmek için simülasyon ile elde edilen veriler yerine gerçek hayattan toplanmış veriler tercih edilmelidir. Yapılan araştırmalar sonrası bu özelliğe uygun hem sürücü davranışı hem de lidar, kamera gibi sensörlerden elde edilen gerçek hayat verileri bulunan DBNET [28] veri setinin kullanılmasına uygun görülmüştür. Aşağıda hem bu tezde kullanılan DBNET veri

seti hem de sürücüsüz araç çalışmalarında yaygın olarak kullanılan diğer veri setleri ile ilgili bir karşılaştırma yapılmıştır.

Otonom sürüş alanında veri seti arařtırmalarında veri kümelerinin farklı özellikleri ve kriterleri vardır. Comma.ai [29] veri seti araç hızı, direksiyon açısı bilgileri ve kamera, GPS, jiroskop, IMU gibi sensörlerden gelen verilerden oluşur. Ancak bu veri seti, genel sürüş politikası öğrenimi için uygun olmayan yalnızca otoyol sürüş senaryolarına odaklanır. Comma.ai veri seti DBNET veri seti gibi sürücü davranış verilerine sahiptir. Comma.ai veri setinde DBNET veri setinin aksine lidar verileri bulunmamaktadır. KITTI[30,31] insanlara ve araçlara ait gerçek sahnelere ait kamera ve lidar görüntülerinden oluşur. Ancak, KITTI yalnızca daha az yoğun trafik sahnelerinden oluşur. Başka bir deyişle, KITTI önemli ölçüde daha az insan ve daha fazla kalabalık olmayan yol sahnesi sergiler, bu da çeşitlilik eksikliğine neden olur. KITTI veri setinde sürücü davranış verileri bulunmamaktadır. OXFORD [32] veri seti lidar, GPS, INS ve 6 monte edilmiş kameradan toplanan yaklaşık 20 milyon görüntüsü ile 1000 km'den fazla kayıtlı sürüş içerir. Ayrıca şiddetli yağmur, gece, direkt güneş ışığı ve kar dahil tüm hava koşullarında toplanmıştır. OXFORD veri seti birçok senaryo barındıran kapsamlı bir veri seti olmasına rağmen bu veri setinin eksikliği KITTI veri setinde olduğu gibi karar tahmini için büyük önem taşıyan sürücü davranışlarını bulunmamasıdır. DBNET veri seti lidar tarafından taranan büyük ölçekli, yüksek kaliteli nokta bulutları ve bir ön panel kamerası tarafından kaydedilen görüntülere sahip bir veri setidir. DBNET veri seti, KITTI ve OXFORD veri setinin aksine karar tahmini için büyük önem taşıyan sürücü davranışlarını atlamaz; görüntüler ile eşleşen sürücü davranışları barındırır. Bu nedenle alanında diğer yayınlanan veri setlerinden farklı bir veri setidir. Veri toplama aracı, trafik levhaları, trafik ışıkları, yayalar ve araçlar gibi nesnelerin bulunduğu yapılandırılmamış karmaşık bir sürüş güzergahında verileri toplamıştır. Aynı şekilde araç, geniş caddelerde, anayolda, dağ yolunda, okul yolunda ve dar sokaklar da sürüş yaparak veriler toplamıştır. DBNET veri seti 1000 km'lik gerçek dünya sürüş verilerini yakalayan hizalanmış video, nokta bulutu, GPS ve sürücü davranışlarını içerir. Bu çalışmada 17040 kamera verisi 17040 lidar verisi ve 17040 sürücü davranış verisi kullanılmıştır. Bu verilerin 12240 adedi eğitim verisi 2400 adedi doğrulama verisi, 2400 adedi ise test verisi olarak kullanılmıştır.

3.2. DERİN ÖĞRENME VE KULLANILAN METOTLARI

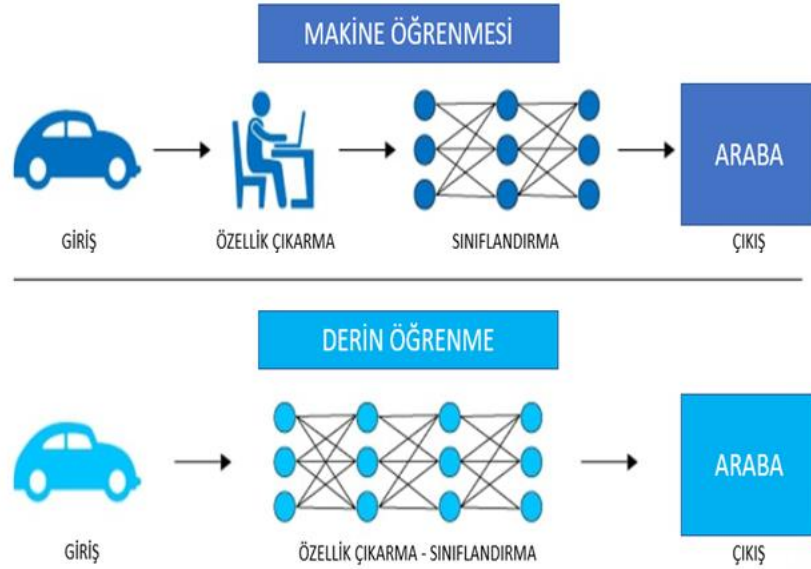
Yapay zekâ kavramı ilk olarak 1950’li yıllarda Alan Mathison Turing ve John McCarthy tarafından ortaya atıldı. Yapay zekâ kısaca insan zekasını taklit etmeye çalışan sistemlere verilen genel bir isim olarak tanımlanabilir. Yapay zekâ kavramı, basit bir sayı dizisinin küçükten büyüğe doğru sıralamasından, bir aracın sürücüsüz olarak nasıl seyahat edeceğini öğrenmesine kadar insan zekasını taklit etmeye çalışan her yaklaşımı içine alır. Yapay zekâ alanı alt kümelerle ayrılır. Çok popüler olan makine öğrenmesi ve derin öğrenme yapay zekânın alt kümelerindedir. Şekil 3.1’de bu alt kümeler gösterilmektedir.



Şekil 3.1. Yapay zekâ, makine öğrenmesi, derin öğrenme arasındaki ilişki.

Birçok kişi tarafından derin öğrenme ve makine öğrenmesi birbirinin yerine kullanılan sözcükler olarak karıştırılmaktadır. Bu hatalı kullanım zaman zaman yapay zekâ alanının daha iyi anlaşılmasını engellemektedir. Bu nedenle yapay zekâ alanında araştırma yapılmadan önce bu alanla ilgili terimleri ve terimler arasındaki farklılıkları doğru öğrenmek çok önemlidir. Makine öğrenimi, bilgisayarların verilerden öğrenebilme kabiliyetinin genel adıdır. Makine öğrenimi, verileri ayrıştıran, bu verilerden öğrenen ve daha sonra öğrendiklerini bilinçli kararlar vermek için uygulayan algoritmaları içeren bir yapay zekâ uygulamasıdır. Derin öğrenme algoritmaları da bir makine öğrenmesi algoritmalarıdır. Derin öğrenmeyi

makine öğrenimi alanında özel kılan şey, kullanılan yapay sinir ağı (YSA) yapısının, daha az insan müdahalesi ihtiyacı ve daha büyük veriye gereksinim duymasındır. Geleneksel makine öğrenmesi algoritmalarında doğrusal regresyon, karar ağacı, basit YSA vb. kullanılırken derin öğrenme çok katmanlı YSA'ya dayanmaktadır. Derin öğrenme algoritmalarındaki çok katmanlı YSA, insan beyni gibi karmaşık ve iç içedir. Derin öğrenme algoritmalarına çok daha az insan müdahalesi gerektirir. Makine öğrenmesi ve derin öğrenme arasındaki fark Şekil 3.2'de açıklanmıştır. Derin öğrenme algoritmasının düzgün çalışması için geleneksel bir makine öğrenme algoritmasından çok daha fazla veriye ihtiyacı vardır. Makine öğrenimi binlerce veriye ihtiyaç duyarken, derin öğrenme modeline çoğu zaman eğitim için milyonlarca veri verilmesi gerekebilir. Karmaşık çok katmanlı yapısı nedeniyle, bir derin öğrenme sistemi, dalgalanmaları ortadan kaldırmak ve yüksek kaliteli yorumlar yapmak için büyük bir veri kümesine ihtiyaç duyar.




Şekil 3.2. Derin öğrenme ve makine öğrenmesi [33]'den alınarak düzenlenmiştir.

Sürücüsüz araçtaki ulaşılmak istenen hedef, bir araç sürücüsünün tüm sürüş görevlerini hatta daha fazlasını sürücüsüz aracın harici hiçbir müdahale olmaksızın yapabilme kabiliyeti kazanmasıdır. Bu hedefe ulaşılması için sürücüsüz aracın gerçek hayattaki hemen hemen her senaryoyu öğrenmesi gerekmektedir. Sadece gerçek hayattaki senaryoları öğrenmesinin yanında eldeki senaryolardan kendisinin yeni senaryolar oluşturarak o senaryolarından öğrenmesi bile gerekebilir. Bu tarz bir

öğrenme için çok fazla sensör verilerine ihtiyaç vardır. Makine öğrenmesi matematiksel temellere dayanmaktadır ve bir sürücüsüz aracın sensör verilerinden yönlendirme komutlarının belirleme becerisini öğrenmesi çok fazla matematiksel işlem ve hesap yoğunluğu gerektirmektedir. Sürücüsüz bir araç problemi çok kompleks bir problemdir. Veri fazlalığı sebebiyle bu konuda geleneksel makine öğrenmesi yetersiz kalmaktadır. Derin öğrenme ise çok katmanlı yapay sinir ağı yapısı ile sürücüsüz araçlar için bir dönüm noktası olmuştur.

Derin öğrenme büyük miktarda verileri işleme yeteneği nedeniyle yapay zekâ uygulamaları için çok güçlü bir araçtır. Derin öğrenmede bir katmanın genel prensibi kendinden önceki katmanın çıktısını, kendisinin girdisi olarak kabul etmesidir. Derin öğrenmenin farklı mimarileri vardı. Evrişimli Sinir Ağı büyük miktarda veriler işleyen derin öğrenmenin günümüzdeki popüler mimarilerinden biridir. 1998 yılında tasarlanılan ve ilk başarılı sonuç veren evrişimli sinir ağı modeli LeNet-5 modelidir. LeNet ağı 2 evrişim ve 3 tam bağlı katman ile toplam 5 katmana sahip bir ağıdır. LeNet – 5 evrişimli sinir ağı modeli aktivasyon işlevine sahip evrişimleri istifleme, katmanları bir araya getirme ve ağı bir veya daha fazla tam bağlantılı katmanla sonlandırma konusunda bir standart haline gelmiştir [34].




Şekil 3.3. LeNet modeli.

1998 yılındaki yayınlanan LeNet evrişimli sinir ağı modeli Şekil 3.3' te verilmiştir. Evrişimli sinir ağının çalışma prensibi şöyle özetlenebilir. Modele girdi olarak 32x32' lik tek kanallı bir görüntü verilmiştir. İlk katmanda 6x6'lık bir filtre uygulanarak 28x28'lik altı kanallı birden çok matris dizisi (tensör) elde edilmiştir. İlk katmandan sonra tek kanallı bir görüntü 28x28x6 kanallı bir öznitelik haritasına dönüşmüştür. Daha sonra havuzlama işlemi gerçekleştirilmiş ve yeni boyut 14x14x6 olarak değişmiştir. Ardından tekrar 16 kanallı bir filtre kullanılarak evrişim işlemi gerçekleştirilmiş 10x10 yükseklik ve genişlikli yeni bir tensör elde edilmiştir. 10x10x16 tensörüne tekrar ortaklama işlemi uygulanmış, 5x5x16'lık yeni tensör elde edilmiştir. Ardından tam bağlı katmanlar ile nöronlar tam bağlanarak 10 çıktılı bir çıkış elde edilmiştir[35]. 2012 yılında ise AlexNet modeli tasarlanmıştır. AlexNet evrişimli sinir ağı 5 evrişim ve 3 tam bağlı katman ile toplam 8 katmana sahip bir ağıdır. AlexNet evrişimli sinir ağı modeli LeNet modeline benzemektedir. AlexNet modelinde maksimum havuzlama işlemi yapılmaktadır[36]. 2014 yılında ise VGG-16 evrişimli sinir ağı modeli tasarlanmıştır. Bu evrişimli sinir ağı 13 evrişim ve 3 tam bağlı katman ile toplam 16 katmana sahiptir. Bu modelde evrişim katmanları ikili ya da üçlü kullanılmıştır. VGG-16 modelinde maksimum havuzlama işlemi yapılmaktadır [37]. Sonraki yıllarda bu tezde de kullanılan Inception, Densenet, Resnet ve PilotNet gibi daha kompleks ve gelişmiş derin öğrenme modelleri geliştirilerek çok daha büyük ve hesap gerektiren veri işlemleri olan yapay zekâ uygulamalarının kullanımına sunulmuştur. Bu tezde bu dört kompleks ve gelişmiş derin öğrenme modelleri kullanılarak sürücüsüz araç eğitimi gerçekleştirilmiştir.

3.2.1. Resnet

Derin öğrenme modellerinde katman sayısı arttıkça bazı problemler gözlemlenmeye başlandı. Çok katmanlı bir derin öğrenme modelinde her bir katman sadece önceki katmana bağlı olarak tasarlanırsa, bu tasarımın teorik olarak eğitilen ağıdaki eğitim hatasını azaltması beklenir. Pratikte bu her zaman böyle olmamaktadır. Öğrenmenin gerçekleşmediği aradaki bazı katmanlar eğitimi negatif olarak etkilemektedir. Bu problemi çözmek için Resnet derin öğrenme modelinde geliştirilmiştir [38]. Resnet modelinde, eğitim esnasında gizli katmanlardaki eğitime katkı vermeyen nöronların olumsuz etkisini ortadan kaldırmak için, her iki katmanda bir, katmanların girişi artık

(residual) bloklar yardımıyla katman çıkışına eklenmiştir (Şekil 3.4). Böylece katmanların eğitimi olumsuz etkilemesinin önüne geçilmiştir. Özellikle 100 ve üzeri çok katmanlı ağlarda Resnet modelinin eğitim hatası üzerindeki olumlu etkisi bir sıralı bağlanmış çok katmanlı derin öğrenme ağına kıyasla çok net bir şekilde görülmüştür. Aşağıda Resnet modelin 34 katmanlı yapısının örneği verilmiştir.

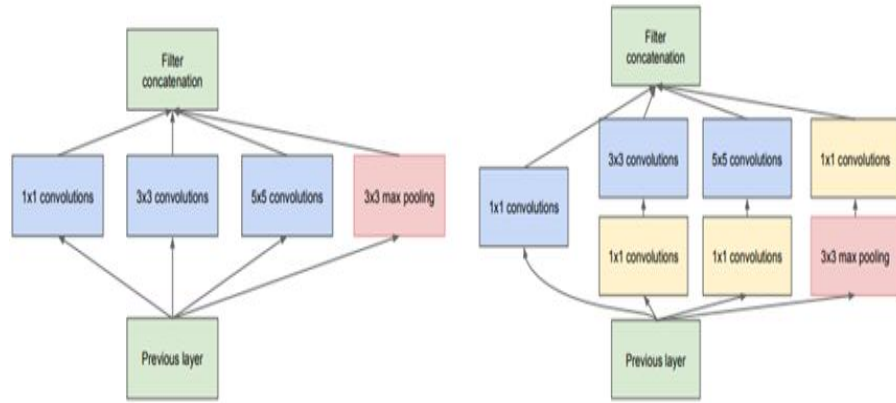


Şekil 3.4. Resnet modeli [38].

Resnet modeli genellikle görüntü sınıflandırma ve tanıma problemlerinde kullanılmaktadır ve sürücüsüz araç çalışmalarında da kullanılmıştır[39]. Resnet modelinin farklı katman sayılarına göre birçok farklı modeli bulunmaktadır. Bu tezde 152 katmanlı Resnet-152 modeli kullanılmıştır.

3.2.2. Inception

Sürücüsüz araç çalışmalarında kullanılan bir diğer öğrenme mimarisi Inception modeldir [40]. Inception model yüksek hesaplama yükünü iç içe ağlar kullanarak düşürmeyi amaçlamıştır. Inception modülünde giriş üzerine farklı boyutlu maksimum havuzlama işlemi uygulanmaktadır. Bu işlemler sonunda çıktılar birleştirilir ve bir sonraki modüle gönderilir. Burada çıkış boyutu ve işlem karmaşıklığı artmaktadır. Bu problemi çözmek için 1x1 evrişim katmanları kullanılır. Derin öğrenme ağlarındaki yüksek matematiksel hesaplama yükünü daha az hale getirebilmek için Inception-V1 modelinde farklı boyutlardaki evrişim işlemlerinden önce fazladan 1x1 evrişim işlemi eklenerek giriş kanallarının sayısı azaltılmaktadır (Şekil 3.5).




INCEPTION-V1

INCEPTION-V1 (Boyut Azaltılmış)

Şekil 3.5. Inception-V1 modeli [40].

2015 yılında inception derin öğrenme modelinin Inception-V2 ve Inception-V3 adında yeni modelleri yayınlandı [41]. 2017 yılında bu tezde de kullanılan Inception-V4 model versiyonları yayınlandı [42]. Inception genellikle nesne tespiti, görüntü sınıflandırma gibi problemlerde kullanılmaktadır.



INCEPTION-V4

STEM

INCEPTION-A

INCEPTION-B


INCEPTION-C

Şekil 3.6. Inception-v4 modeli [42].

Şekil 3.6 Inception-V4 derin öğrenme modeli tüm parçalarıyla detaylı bir şekilde verilmiştir. Örnek olarak [43] sürücüsüz araç çalışmasında inception derin öğrenme modeli kullanmıştır.

3.2.3. DenseNet

Densenet sürücüsüz araç çalışmalarında yerini alan diğer bir modeldir [44]. Densenet derin öğrenme modeli, bazı temel farklılıklarla Resnet'e oldukça benzer bir modeldir. Resnet derin öğrenme modelinde, her iki ağ katmanda bir ağ katmanının girişi artık bloklar yardımıyla ağ katmanı çıkışına eklenirken Şekil 3.7' de gösterildiği gibi Densenet modelinde girişler ve katman çıkışları tüm katmanları beslemektedir bu yönüyle katmanların bağlanmasında farklılık vardır. Bu tezde 169 katmanlı bir Densenet model kullanılmıştır.




Şekil 3.7. Densenet modeli [45].

Densenet genellikle nesne tespiti, görüntü sınıflandırma gibi problemlerde kullanılmaktadır.

3.2.4. PilotNet

PilotNet derin öğrenme modeli, Resnet-152, Inception-v4, Densenet-169 derin öğrenme modellerine göre daha az katmanlı bir modeldir. PilotNet derin öğrenme modeli uçtan uca öğrenme metodunun mantıksal yapısına göre tasarlanmış bir modeldir ve yapılan çalışmalarda uçtan uca öğrenme metodunda güzel sonuçlar verdiği gözlemlenmiştir [28,44,46]. PilotNet derin öğrenme modeli normalizasyon katmanı, 5 evrişim katmanı ve 3 tam bağlantılı katman dahil olmak üzere toplam 9 katmandan oluşur [47].



Şekil 3.8. PilotNet modeli modeli.

Şekilde görüldüğü gibi ağın ilk katmanında ağa verilen görüntülere bir normalizasyon işlemi uygulanır. Daha sonra sırasıyla üç defa 5x5 ve iki kez 3x3 evrişim işlemi uygulanmaktadır. Evrişim katmanları özellik çıkarımı gerçekleştirmek için tasarlanmıştır. Sonraki sırasıyla 100,50,10 nöron bulunan katmanlar birbirlerine tam bağlı katman metoduyla bağlanır ve çıktı elde edilmektedir. Evrişimli katmanlar, özellik çıkarımı gerçekleştirmek için tasarlanmıştır.

3.3. VERİLERİN DÜZENLENMESİ

Bu tezde DBNET veri setinde sunulan ham veriler üzerinde tezin amacı doğrultusunda farklı işlemler uygulanmıştır.

Bu işlemler sırasıyla; kamera görüntülerinin kırılması, lidar sensör verilerinin filtrelenmesi ve kamera görüntülerinin semantik etiketlenmesidir. Aşağıda sırasıyla eğitimlerde kullanılan kamera, lidar, sürücü davranışı ve semantik görüntüler açıklanmıştır.

3.3.1. Kamera Görüntülerinin Kırılması

Kamera verileri, aracın sağ üst köşesindeki saniyede 30 görüntü yakalayan bir araç kamerası ile toplanmıştır. Görüntüler 1920x1080 pikseldir. Bu tezde ham kamera görüntüleri iki farklı şekilde kullanılmıştır.

- Az Kırılmış Görüntü 1080x600 piksel
- Fazla Kırılmış Görüntü 940x400 piksel

Kırma işleminde temel amaç eğitim ve test doğruluğunu bozmadan eğitim süresini azaltmaktır. Şekil 3.9'da görüldüğü gibi ham görüntü üzerinde iki farklı oranda kırma gerçekleştirildi. Kırılmalarda gökyüzü ve bazı binalar gibi gereksiz kısımlar görüntüden kaldırıldı. Kırılmalar bir Python kodu yardımıyla toplu bir şekilde yapılmıştır. Toplu yapıldığı için arada hatalı kırılmalarda tespit edilmiştir. Bu tespit edilen hatalı kırılmış görüntüler veri setinden tek tek elle ayıklanmıştır.



Şekil 3.9. Fazla kırılmış – az kırılmış kamera görüntüleri

Az kırılmış gökyüzü, yol veya yol çevresiyle ilgili fazla kırılmış görüntüye kıyasla fazla detay vardır. Fazla kırılmış görüntüde yol dışındaki nesnelere ilgili bilgi azdır.


3.3.2. Lidar Sensör Verilerinin Filtrelenmesi

Temel olarak, lidar, bir uzaktan algılama işlemidir. Lidar nesnelere ve ortamların 3 boyutlu modellerini ve haritalarını oluşturur. Lidar ultraviyole, görünür veya yakın kızılötesi frekanslarında darbe gönderir ve gönderdiği sinyallerin nesnelere yansıtılarak tarayıcıya geri dönmesi için geçen süreyi ölçerek uzamsal ilişkileri ve şekilleri belirler. Lidar sistemleri darbenin isabet ettiği her şeyin yönü ve mesafesi bir veri noktası olarak kaydedilir. Zemin, binalar, orman gölgesi, otoyol üst geçitleri ve lazer ışınının araştırma sırasında karşılaştığı diğer her şey için yükseklikler nokta bulutu verilerini oluşturur [48].

Veri setindeki lidar verileri, araca yerleştirilen bir lidar tarayıcı ile toplanmıştır. Kullanılan tarayıcının lazer ışını saniyede 10 kere ışın demeti göndermektedir, lazer

ışınının derinliği 2 cm çözünürlük ile 1 metreden 70 metreye kadardır, tarama açısı aralığı ise dikeyde + 10,67 ile - 30 ,67 derece, yatayda 360 derecedir.

Veri setinde, tek bir lidar verisi 700000 noktadan oluşmaktadır. Bu nokta sayısı çok büyük olduğu için öğrenme için uygun olan noktaların seçilmesi gerekmektedir. Çalışmamızda lidar noktaları seçilirken CloudCompare programı ile SOR filtresi kullanılmıştır. SOR filtresi her noktanın komşuluğu üzerinde istatistiksel bir analiz yaparak ve belirli bir kriteri karşılamayanları kırpar ve seyrek aykırı değerleri kaldırır. Seyrek aykırı değer kaldırma işlemi, girdi veri setindeki noktaların komşularına olan uzaklık dağılımının hesaplanmasına dayanmaktadır. Her nokta için, bu noktadan tüm komşularına olan ortalama mesafe hesaplanır. Ortaya çıkan dağılımın bir ortalama ve bir standart sapma ile Gauss olduğu varsayılır. Sor filtresi uygulamamızın nedeni lidar taramalarının genellikle değişen nokta yoğunluklarında nokta bulutu veri kümeleri oluşturması ve bunun eğitimi olumsuz etkileyen ölçüm hatalarına ve aykırı değerlere yol açmasıdır [49].



Şekil 3.10. Lidar filtreleme.

Şekil 3.10’da bir lidar verisinin ham hali, gürültü filtresi ve SOR filtre uygulanmış hali gösterilmiştir. SOR filtre ham görüntüyü daha fazla temizlemiştir. Görseller Cloud Compera programı ile görselleştirilmiştir.

3.3.3. Sürücü Davranışları

Veri setinde iki sürücü davranışı verilmiştir.

- Araç Direksiyon Açısı
- Araç Hızı


Her bir kamera görüntüsü ve lidar görüntüsü ile sürücünün bu görüntüler esnasında ürettiği araç direksiyon açıları ve araç hızları birebir eşlenmiştir. Şekil 3.11’de bir davranış dosyasının örneği verilmiştir.

Direksiyon Açısı	Araç Hızı
0	29
0	28
0	28
2	28
6	28
5	28
30	27
44	25
45	24
46	24
55	23
53	23
53	24
72	23
87	23
86	22
83	22
67	23
20	25
4	26
0	26

Şekil 3.11. Sürücü davranışı dosyası.

3.3.4. Kamera Görüntüsü Semantik Etiketlenmesi

Semantik yaklaşımda, bir görüntünün aynı nesne sınıfına ait olan kısımları tespit edilmektedir. Bu bir görüntüdeki her pikselin bir kategoriye göre sınıflandırılması anlamına gelir. Çalışmamızda kentsel yoğun bir trafik akışına sahip koşullarda, elde edilen görüntülere, genellikle off-road yollarda kullanılan [3] ikili semantik sınıflandırma uygulanmış ve eğitim bu semantik işlemi uygulanan görüntüler ile gerçekleştirilmiştir. Öncelikle asfalt, araç için seyahat edilebilir olarak etiketlenmiştir. Sonrasında ise asfalt dışında kalan, her şey seyahat edilemez olarak etiketlenmiştir. Yapılan işlem Şekil 3.12’de görülmektedir. Tüm resimler tek tek matlab programı ile elle etiketlenmiştir.



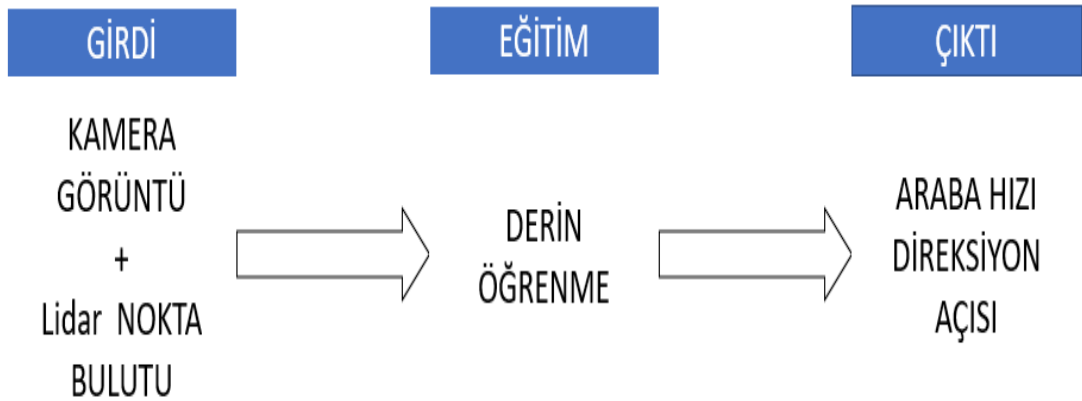
Şekil 3.12. Semantik etiketleme.

3.4. DENEYLER

Bu tezde, sürücüsüz aracın eğitimindeki optimum verilerin ve en uygun derin öğrenme modelinin tespiti için farklı deneyler yapılmıştır. Deney prosedürleri aşağıdadır.

3.4.1. Deney A


Deney A Şekil 3.13’de görüldüğü gibi lidar ve kamera görüntülerini giriş olarak kullanır. Deney A, PilotNet derin öğrenme modeli ile gerçekleştirilmiştir. Bundan sonraki deneylerde kullanılacak batch size boyutu, lidar nokta sayısı ve kamera görüntü kırpma oranını belirlemek için bu deney yapılmıştır.



Şekil 3.13. Deney A tasarımı.

3.4.2. Deney B

Deney A ile takip eden deneylerde kullanılacak batch size boyutu, lidar nokta sayısı ve kamera görüntü kırpma oranı bulunurken Deney B’de bu değerler kullanılarak, Inception-V4, Resnet-152, PilotNet ve Densenet-169 derin öğrenme modelleri eğitilmiştir. Modellerin sadece kamera verileri ile eğitilmesi ile hem kamera hem de lidar verileri ile eğitilmesi arasındaki fark incelenmiştir.

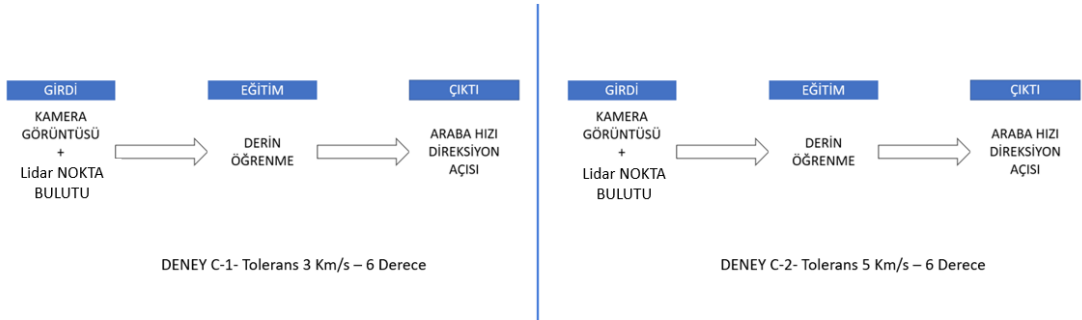


Şekil 3.14. Deney B-1 (sol) ve B-2 (sağ).

Şekil 3.14'te Deney B'nin tasarımı görülmektedir. Deney B-1'de ağ girişi yalnızca kamera verileri iken B-2'de giriş kamera ve lidar verileridir.

3.4.3. Deney C

Deney C'de Inception-V4, Resnet-152, PilotNet ve Densenet-169 ağlarının girişi kamera ve lidar verileri iken, farklı hız ve açı toleransı değerlerinin eğitim doğruluğunu nasıl etkilediği araştırılmıştır.

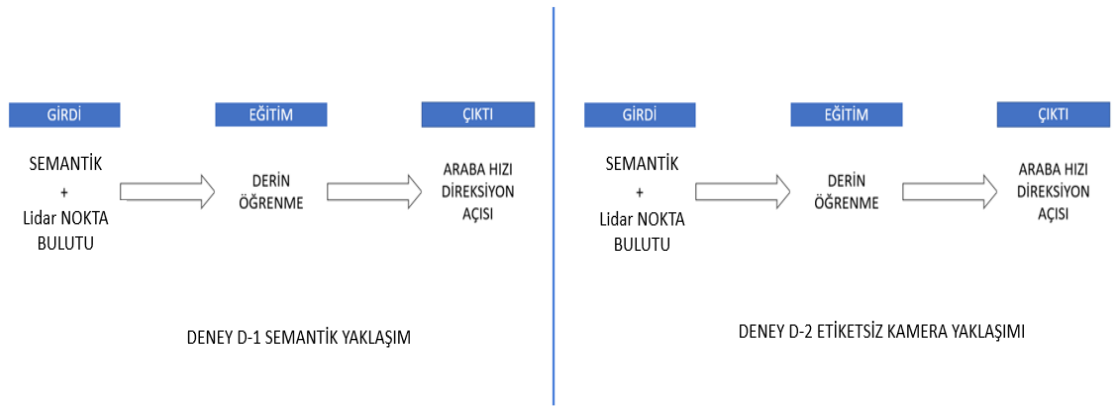


Şekil 3.15. Deney C.

Şekil 3.15'te Deney C-1'e eğer gerçek değer ile tahmin edilen sürücüsüz araç hızı arasındaki farkın mutlak değeri 3 Km/s'den büyükse bu tahmin hatalıdır şeklinde öğrenme yaptırılmıştır. Deney C-2'de ise bu öğrenme eğer gerçek değer ile tahmin edilen sürücüsüz araç hızı arasındaki fark 5 Km/s'den büyükse bu tahmin hatalı şeklindedir.

3.4.4. Deney D

Bu deneyde arazi senaryolarında başarıyla kullanılan görüntüler üzerindeki semantik etiketleme yönteminin şehir içi senaryolarındaki başarısı araştırılmıştır. Semantik etiketleme yapılmış görüntüler ve lidar verileri ile eğitilen ağın eğitim performansı D-2 deneyinde elde edilen sonuçlar ile karşılaştırılmıştır. Bu deney 2160 eğitim, 240 doğrulama verisi ile yapılmıştır.



Şekil 3.16. Deney D.

3.5. DEĞERLENDİRME KRİTERLERİ

Bu çalışmada birkaç değerlendirme kriteri kullanılmıştır. İlk kriter doğruluk değeridir. Doğruluk değeri, veri setinde bulunan sürücü davranışı dosyalarındaki gerçek değer ile eğitim sonrası tahmin edilen sürücü davranışı arasındaki ilişkidir. Doğruluk değerinin bulunması için gerçek sürücü davranışı değeri ile tahmin edilen sürücü davranışı değeri arasındaki farkın mutlak değeri hesaplanmaktadır. Eğer bu fark belirlenen tolerans değerlerinin arasındaysa tahmin edilen değer doğru kabul edilmektedir. Fakat belirlenen tolerans değerinin dışındaysa hatalı tahmin olarak kabul edilmektedir. Örnek olarak: sürücü davranışı hız verisi 15 km/s ve direksiyon açısı verisi 20 derece olsun ve tolerans değerimiz hız için 6 km/s direksiyon açısı için 3 derece şeklinde belirlensin. Eğitim sonrasında tahmin edilen hız değeri 18 km/s ise gerçek değer ile tahmin edilen değer arasındaki fark eğer 6 km/s'den az olduğu için tahmin edilen değer doğru kabul edilecektir. Eğer tahmin edilen değer 22 Km/s ise fark 6 km/s'den fazla olduğu için tahmin yanlış kabul edilecektir. Aynı durum

direksiyon açısı içinde geçerlidir. Burada önemli olan nokta, tolerans değerinin nasıl belirlenmesi gerektiğidir. Bu sebepten dolayı bu çalışmada farklı tolerans değerleri belirlenerek farklı doğruluklar elde edilmiş literatüre katkı sunması amacıyla dördüncü bölümde tablolar ile gösterilmiştir.Çizelge 3.1.' de hız ve açı için belirlenen tolerans değerleri verilmiştir.

Çizelge 3.1. Tolerans değerleri.

	Tolerans 1	Tolerans 2	Tolerans 3	Tolerans 4	Tolerans 5
Araç Hızı (Km/s)	1	2	3	4	5
Direksiyon Açısı (Derece)	1,2	2,4	3,6	4,8	6,0

Bir diğer kriter ise ortalama hatadır. Ortalama hata kriteri, uzun vadede genel performansı göstermektedir. Bu değerlendirme kriteri direksiyon açısı veya araç hızı için tüm tahminlerdeki ortalama hatadır. Son kriter ise eğitim esnasında modelin doğruluğunu belirleyen ağırlık değerlerinin güncellenmesinde etkili olan kayıp değerlerinin ortalaması olan ortalama kayıp değeri olarak belirlenmiştir.

Derin öğrenme ağlarında, gelişim süreçlerini ve yenilikleri tetikleyen ana düşünce hesaplama yükünün azaltılması ile ilgilidir. Çok yüksek performanslı bilgisayarlarda bile kırk bin, elli bin görüntünün işlenmesi ve 100 katman üzeri bir ağda eğitilmesi günlerce sürebilmektedir. Milyonlarca verilerle çalışan bir derin öğrenme uygulaması için hesaplama yükünün azaltılması çok değerlidir. Bu hesaplama yükü eğitimde kullanılan verilerin optimum şekilde ayarlanması ile azaltılabilmektedir. Bu tez kapsamında yapılan deneylerdeki eğitim süreleri incelenerek modellerin ve ön işlemlerin eğitim süresine etkisi incelenecektir.

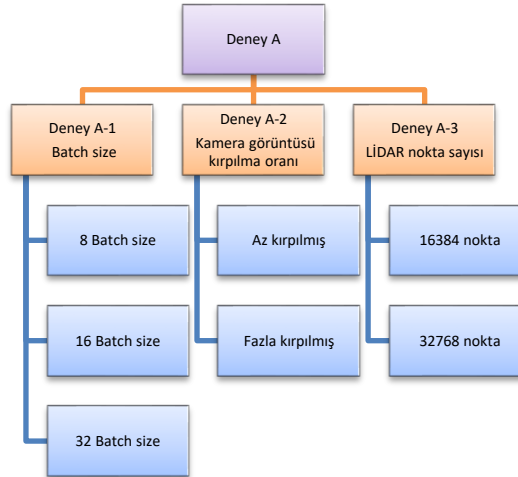
BÖLÜM 4

DENEYSEL SONUÇLAR

Bu bölümde eğitim ve test sonuçları verilmiştir. Eğitimler Nvidia V100 grafik kartına sahip bir bilgisayar üzerinde Python ortamında gerçekleştirilmiştir. Eğitilen uçtan uca sürücüsüz aracın bölüm 3'te belirtilen deneylerdeki eğitim doğruluğu ve test doğruluğu ile ortalama hata ve kayıp değerlerinin sonuçları sunulmuş ve detaylı bir şekilde tartışılmıştır.

4.1. DENEY A

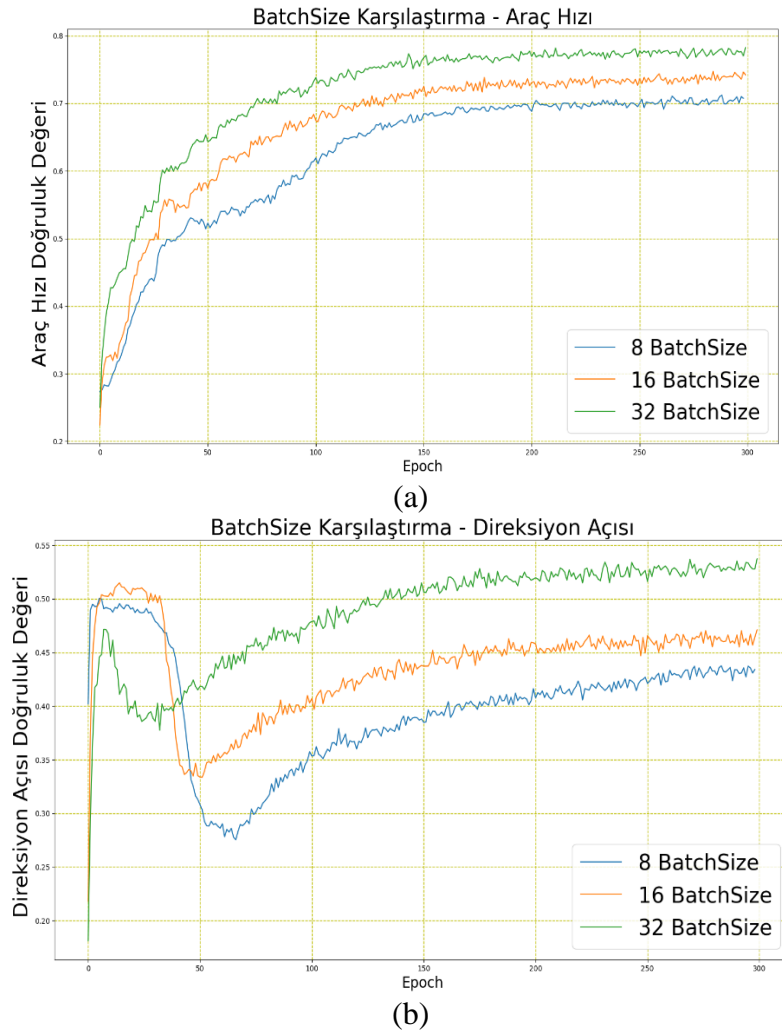
Deney A'da bu tezin diğer deneylerinde kullanılacak batch size, kırılma oranı ve lidar nokta sayısı belirlenmesi için izlenen adımlar Şekil 4.1 verilmiştir.



Şekil 4.1. Deney A kapsamı.

4.1.1. Batch size

Batch size boyutu eğitim esnasında verilerinin nasıl ağı besleyeceğini belirler. Ağın öğrenmesi ve eğitim süresi için önemli bir parametredir. Deney B, C ve D, Deney A'da bu çalışma için uygun olduğu tespit edilen batch size boyutu ile gerçekleştirilmiştir. Şekil 4.2'de derin öğrenme modellerinde sık tercih edilen 8,16,32 batch size boyutları kullanıldığında elde edilen eğitim aşaması doğruluk değerleri verilmiştir.



Şekil 4.2. Farklı batch size değerleri için a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.

Şekil 4.2'de sürücüsüz araç hız tahmini doğruluğunda iki yüzüncü epocha kadar bir artış görülmüştür. İki yüzüncü epochtan sonra doğruluk değerinde artış durmuştur. Bu eğitimin tamamlandığı anlamına gelir. Sürücüsüz araç direksiyon açısında bazı

nedenlerden dolayı sıfır ile ellinci epochlar arasında beklenmeyen bir azalma, ellinci ve iki yüz ellinci epoch değerleri arasında artış görülmektedir. Bunun sebebi ilerleyen kısımlarda anlatılacaktır.


Batch size için 32 boyutu hem araç direksiyon açısı tahmin hem de araç hızı tahmin değerleri için 8 ve 16 batch size boyutlarına göre daha yüksek doğruluk sonucu vermiştir. Batch size boyutu 32 iken daha yüksek doğruluk değerleri elde edilmesinin yanında eğitim süresi de daha kısadır. Batch size 32 ile batch size 8 arasında yaklaşık 2 kat süre farkı vardır. Sonuç olarak B, C, D deneyleri için batch size 32 boyutu uygun olduğuna karar verilmiştir.

4.1.2. Kamera Görüntüsü Kırılma Oranının Eğitime Etkisi


Deney A'nın bu aşamasında iki farklı kırılma oranına sahip kamera görüntüleri kullanılmıştır. Kırılma işleminin nasıl yapıldığı ve kırılma oranları bölüm 3.3.1'de ele alınmıştır. Şekil 4.3 eğitim sonuçları verilmiştir.

Şekil 4.3'te sürücüsüz araç hızı tahmin doğruluk değeri her iki kırılmada da yüz ellinci epocha kadar bir artış görülmüştür. Yüz ellinci epochtan sonra doğruluk değerinde artış durmuş ve eğitim tamamlanmıştır. Sürücüsüz araç direksiyon açısında sıfır ile yaklaşık kırkinci epochlar arasında beklenmeyen bir azalma kırkinci ve iki yüzüncü epoch değerleri arasında artış görülmektedir. İki yüzüncü epoch sonrasında ise eğitim tamamlanmıştır.

Şekillerde görüldüğü gibi kamera görüntülerinin boyutsal değişimi, hız ve açı değerlerinin tahmin başarısını değiştirmemiştir. Hemen hemen aynı doğruluğu veren iki farklı eğitimde en önemli değişiklik hesaplama yükü ve eğitim süresi olmuştur. Görüntünün daha fazla kırılması eğitimin daha kısa sürede sonlanmasını sağlarken ağı tahmin başarısını düşürmemiştir. Bu nedenle takip eden deneylerde daha fazla kırılmış kamera görüntüleri tercih edilmiştir.



(a)



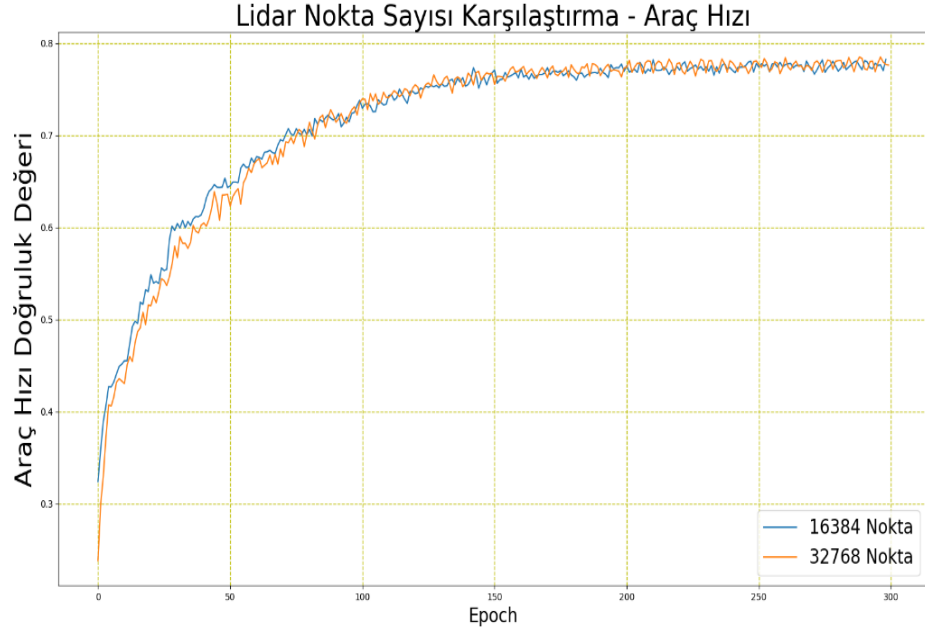
(b)

Şekil 4.3. Farklı kırılmış kamera verileri eğitim sonuçları a) hız b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.


4.1.3. Farklı LİDAR Nokta Sayılarının Eğitime Katkısı

Deney A'nın bu aşamasında 16384 noktadan ve 32768 noktadan oluşan lidar verileri kullanılarak ağ eğitilmiştir. Şekil 4.4'de eğitim sonuçları verilmiştir. Şekil 4.4'de görüldüğü gibi sürücüsüz araç hızı için yüz ellinci epoch sonrası, sürücüsüz direksiyon açısı için iki yüzüncü epoch sonrası eğitimin tamamlanmıştır. Şekilde görüldüğü gibi doğruluk üzerinde yine bir değişiklik görülmemiştir. Eğitim süresi ve hesaplama yükü olarak 16384 lidar nokta sayısı ile 32768 nokta sayısı eğitim süreleri aralarında yaklaşık iki kat süre farkı vardır. 32768 lidar nokta doğruluğu arttırmadığı

gibi eğitim süresini iki kat arttırmıştır. Bu nedenle bundan sonraki deneylerde 16384 noktalı lidar verilerinin yeterli olduğu kanaatine varılmıştır.



(a)

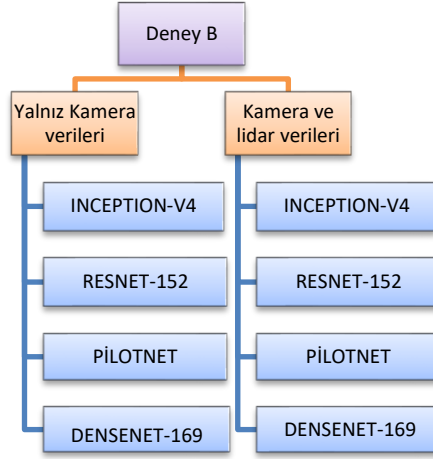


(b)

Şekil 4.4. Farklı Lidar nokta sayısı eğitim sonuçları a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.

4.2. DENEY B

Deney B kapsamında kamera verileriyle beraber lidar verilerinin de eğitimde kullanılmasının 4 modelde de tespit başarısını nasıl etkilediği incelenmiştir. Şekil 4.5'te Deney B'nin kapsamı görülmektedir.



Şekil 4.5. Deney B kapsamı.

Inception-V4, Resnet-152, PilotNet ve Densenet-169 derin öğrenme modelleri ilk olarak Deney B-1 ile eğitilmiştir. Bu eğitimde kullanılan kamera verileri Deney A'da belirlenen fazla kırpılmış kamera verileridir. Derin öğrenme modelleri daha sonra Deney B-2 ile eğitilmiştir. Bu eğitimde Deney A'da belirlenen hem fazla kırpılmış kamera hemde 16384 noktalı lidar verileri kullanılmıştır. Eğitimler doğrulama veri seti ile test edilmiştir. Sonuçlar Çizelge 4.1'de gösterilmiştir.

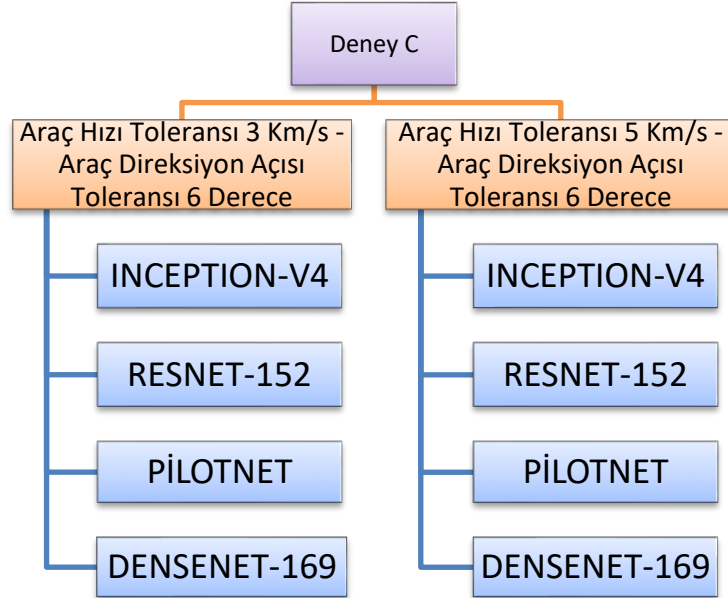
Çizelge 4.1. Deney B sonuçları

DERİN ÖĞRENME MODELLERİ	KONTROL KOMUTLARI	DENEY B-1 (%)	DENEY B-2 (%)
INCEPTION-V4	Sürücüsüz araç direksiyon açısı	46	57
	Sürücüsüz araç hızı	66	71
RESNET-152	Sürücüsüz araç direksiyon açısı	48	62
	Sürücüsüz araç hızı	68	80
PİLOTNET	Sürücüsüz araç direksiyon açısı	66	82
	Sürücüsüz araç hızı	82	96
DENSENET-169	Sürücüsüz araç direksiyon açısı	26	51
	Sürücüsüz araç hızı	46	61

Çizelge 4.1’de görüldüğü gibi Deney B-2 daha iyi doğruluk performansı vermiştir. Burada lidar verileri eğitim süresini yaklaşık iki kat arttırmıştır, fakat tahmin doğruluğunda gözle görülür bir iyileşme görülmüştür. Doğruluk bizim için daha değerli bir kriter olduğu için Deney B-2 daha iyi bir tasarım olarak kabul edilmiş ve Deney C ve Deney D’de Deney B-2 tasarımı kullanılmıştır. PilotNet derin öğrenme modeli en iyi sonuçları veren modeldir. Resnet derin öğrenme modelinin verdiği sürücüsüz araç hızları da kabul edilebilecek seviyededir. Densenet derin öğrenme modelinin sonuçları en kötü sonuçlardır.

4.3. DENEY C

Araç hızı tahminindeki tolerans değerinin hem eğitim hem de test aşamasındaki ağ performansına etkisini incelemek için Deney C yapılmıştır. Bu deneyde sürücüsüz araç hızı için iki farklı tolerans değeri seçilerek eğitimler yapılmıştır. Bu tolerans değerleri sırasıyla 3 km/s ve 5 km/s fark olarak belirlenmiştir. Sürücüsüz araç direksiyon açısı tahminindeki tolerans değeri 6 derece olarak ayarlanmıştır. Deney C’nin kapsamı Şekil 4.6’de verilmiştir.

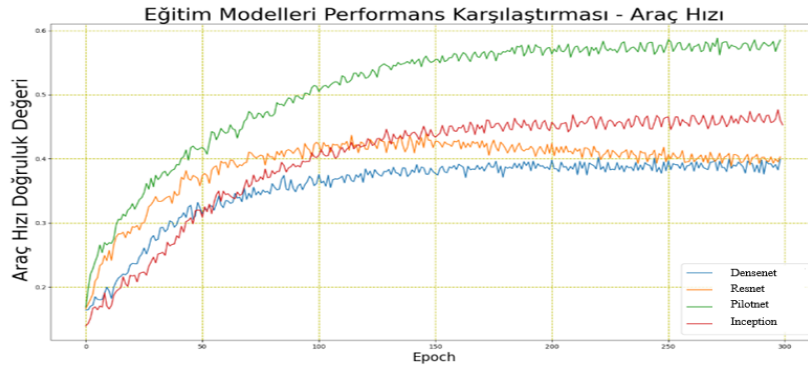


Şekil 4.6. Deney C kapsamı.

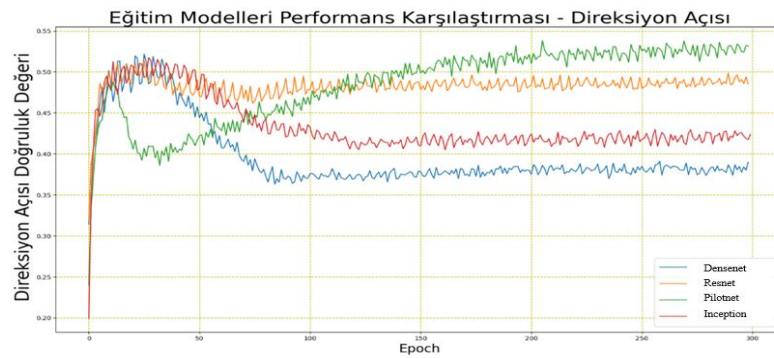
4.3.1. 3 Km/s ve 6 derece tolerans ile elde edilen sonuçlar

Derin öğrenme modelleri eğitilirken her bir epochta beklenen değer ile tahmin edilen değer arasındaki farka göre ağırlıklar güncellenir. Bu güncellemede eğitimin doğru gidip gitmediğine bakılır ve güncelleme ona göre yapılır. Eğitimin doğru devam edip etmediği kararı da bizim doğruluk kriterimize yani toleransımıza bağlıdır. Bunlar göz önünde bulundurularak farklı tolerans değerleri ile eğitimler yapılmıştır. Bu kısımda sürücüsüz araç hızını 3 km/s ve Sürücüsüz Araç Direksiyon Açısı 6 derece olarak ayarlandı ve eğitim sürecinde öğrenme bu tolerans kriterlerine göre yapıldı.

Şekilde Inception-V4, Resnet-152, PilotNet ve Densenet-169 derin öğrenme modellerinin eğitim sonuçlarının grafikleri verilmiştir.



(a)




(b)

Şekil 4.7. 6 derece açı – 3 Km/s hız tolerans eğitim sonuçları a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.

Şekil 4.7 görüldüğü gibi sürücüsüz araç hızı ve direksiyon açısı tahmini doğruluk değerinde PilotNet model en fazla doğruluk veren model olmuştur. Sürücüsüz araç hızı tahmininde PilotNet modelden sonra sırasıyla Inception-v4, Resnet-152 ve

Densenet-169 modelleri yüksek doğruluk vermiştir. Direksiyon açısında ise PilotNet modelinden sonra Resnet-152, Inception-v4 ve Densenet-169 modelleri yüksek doğruluk vermiştir.

Direksiyon açısı tahmini değerlerindeki açıklanması gereken bir durum başlangıçtaki normal olmayan düşüşün sebebidir. Yapılan incelemeler sonucu problemin veri setindeki değerlerin homojen bir şekilde dağılmadığından ortaya çıktığı tespit edilmiştir. Ağların direksiyon açısını tahmin edebilmesi için eğitim esnasında sıfır derece direksiyon açısına karşılık gelen veriler ile çok fazla karşılaştığı tespit edilmiştir. Bu problemin önüne geçmek için veri seti daha homojen hale getirilerek eğitim tekrarlanmıştır. Şekil 4.8’de görüleceği gibi önceki grafiklerde görülen başlangıçtaki hata giderilmiştir.



Şekil 4.8. Düzenlenmiş homojen veri seti.

Fakat verilerin homojenleştirilmesinin ağına ulaştığı nihai doğruluk sonuçlarına etkisi görülmemiştir. Bu nedenle ilk veri seti ile eğitimler yapılmaya devam edilmiştir.

Çizelge 4.2’de eğitilen ağların doğrulama verilerine karşı ürettiği tahmin doğruluğu sonuçları gösterilmiştir. 3 farklı tolerans değerindeki doğruluk değişimleri gösterilmiştir. Doğruluk verileri ile test edilen modellerde en doğru yaklaşım

PilotNet modelinde görülmüştür. Inception-v4 derin öğrenme modeli hariç tüm modellerin test sonuçlarında araç hızı araç direksiyon açısında daha yüksek doğruluk değerleri vermiştir.

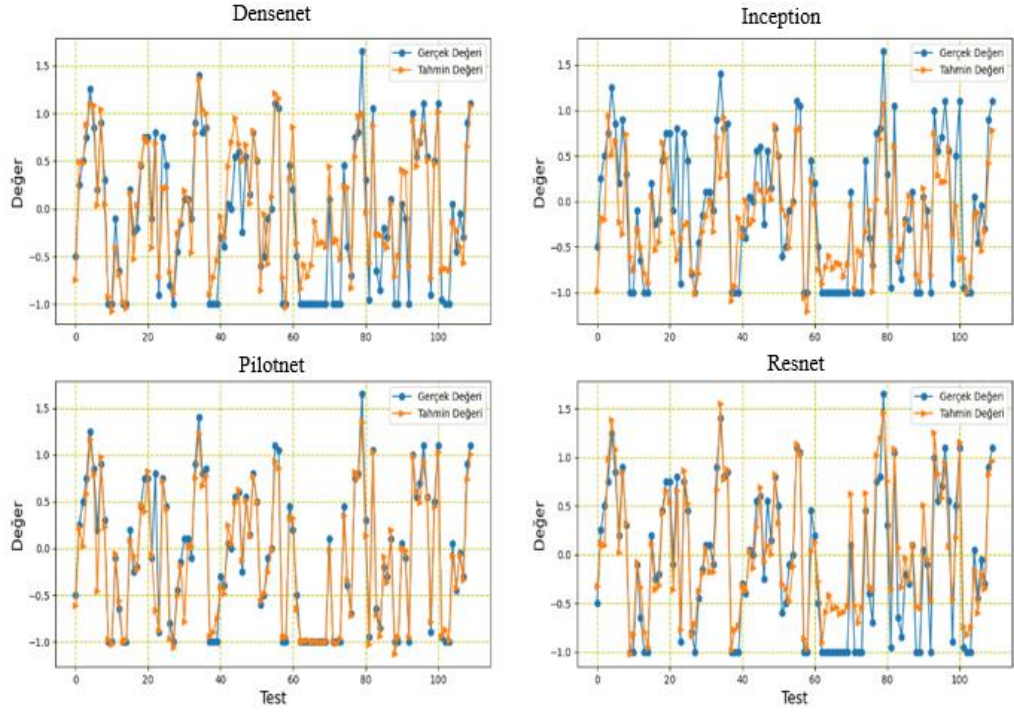
Çizelge 4.2. 3 Km/s ve 6 derece toleransa göre doğruluk sonuçları.

DERİN ÖĞRENME MODELLERİ	KONTROL KOMUTLARI	Tolerans 1 %	Tolerans 2 %	Tolerans 3 %
INCEPTION-V4	ARAÇ DİREKSİYON AÇISI	10	33	52
	ARAÇ HIZI	11	19	29
RESNET-152	ARAÇ DİREKSİYON AÇISI	10	28	30
	ARAÇ HIZI	13	22	40
PİLOTNET	ARAÇ DİREKSİYON AÇISI	32	46	56
	ARAÇ HIZI	45	64	78
DENSENET-169	ARAÇ DİREKSİYON AÇISI	13	24	33
	ARAÇ HIZI	16	26	38

Çizelge 4.2’de tüm modellerin gerçek araç hızı ve direksiyon açısı değerleriyle tahmin edilen araç hızı ve direksiyon açısı değerlerinin doğruluk sonuçları yüzde olarak verilmiştir.

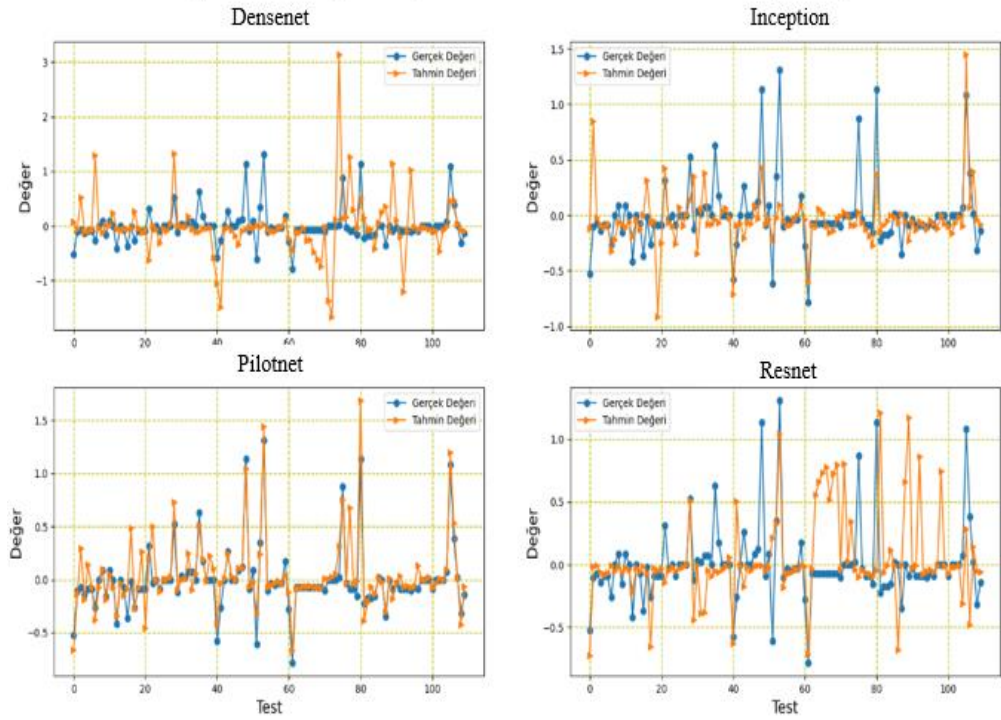
PilotNet ile diğer modeller arasındaki fark Şekil 4.9’da net bir şekilde ortaya konulmuştur. Hem araç hızında hem de direksiyon açısında özellikle 60 ve 70 arasındaki örneklerden oluşan test senaryolarında diğer modeller hatalı bir tahminde bulunurken PilotNet modeli doğru tahminde bulunmuştur.

Gerçek Araç Hızı - Tahmin Edilen Araç Hızı



(a)

Gerçek Direksiyon Açısı - Tahmin Edilen Direksiyon Açısı



(b)

Şekil 4.9. Tahmin – gerçek değer grafiği a) araç hızı b) direksiyon açısı.

Çizelge 4.3. 3 Km/s ve 6 derece toleransa göre ortalama hata ve kayıp.


DERİN ÖĞRENME MODELLERİ	KONTROL KOMUTLARI	TEST HATA ORTALAMA	TEST ORTALAMA KAYIP
INCEPTION-V4	ARAÇ DİREKSİYON AÇISI	10,76	0,175
	ARAÇ HIZI	6,66	
RESNET-152	ARAÇ DİREKSİYON AÇISI	17,26	0,151
	ARAÇ HIZI	4,41	
PİLOTNET	ARAÇ DİREKSİYON AÇISI	5,62	0,035
	ARAÇ HIZI	2,25	
DENSENET-169	ARAÇ DİREKSİYON AÇISI	16,29	0,187
	ARAÇ HIZI	5,08	

Çizelge 4.3'te test edilen modellerin ortalama kayıp ve ortalama hata oranları verilmiştir. Bu çizelgede modellerin performansı arasındaki fark daha belirgin bir şekilde görülmüştür. Densenet-169 derin öğrenme modeli en fazla ortalama kayıp veren modeldir. Ortalama test hatasında direksiyon açısı için en kötü değer Densenet-169 modelinde görülmektedir. Ortalama test hatasında araç hızı için en kötü değer ise Inception-v4 modelinde görülmektedir. Pilotnet derin öğrenme modelinin ise en az kayıp ve hata veren model olduğu görülmüştür.


4.3.2. 5 km/s ve 6 derece tolerans ile elde edilen sonuçlar

Deney C-2'de sürücüsüz araç hızının toleransı 5 km/s ve direksiyon açısı toleransı 6 derece olarak belirlendi. Öğrenme bu tolerans kriterlerine göre gerçekleştirildi.

Inception-V4, Resnet-152, PilotNet ve Densenet-169 derin öğrenme modellerinin eğitim sonuçları Şekil 4.10'te ki grafiklerde verilmiştir.



(a)



(b)

Şekil 4.10. 6 derece açı – 5 Km/s hız tolerans eğitim sonuçları a) araç hızı b) direksiyon açısı tahmin doğruluklarının karşılaştırılması.

Deney C-2'de sürücüsüz araç hızı ve direksiyon açısı tahminlerinde PilotNet modeli en fazla doğruluk veren model olmuştur. Sürücüsüz araç hızında PilotNet modelinden sonra sırasıyla Resnet-152, Inception-v4 ve Densenet-169 modellerinin

yüksek doğruluk verdiği gözlemlenmiştir. Direksiyon açısında ise PilotNet modelinden sonra Resnet-152, Inception-v4 ve Densenet-169 modellerinin yüksek doğruluk verdiği gözlemlenmiştir.

Çizelge 4.4'te beş farklı tolerans değerindeki doğruluk değişimleri gösterilmiştir. Doğruluk verileri ile test edilen modellerden en iyi sonuç veren modelin PilotNet modeli olduğu görülmüştür. Burada asıl dikkat edilmesi gereken eğitim toleransı 3 Km/s ile 5 Km/s ayarlanması arasındaki doğruluk farkıdır. Çizelge 4.4 ve Çizelge 4.2'ye bakıldığında özellikle PilotNet modelinde eğitim toleransı araç hızı için 3 km/s direksiyon açısı için ise 6 derece şeklinde belirlenerek eğitim yapılan deney, araç hızı için 5 km/s direksiyon açısı için ise 6 derece şeklinde belirlenerek eğitim yapılan deneye göre daha düşük bir doğruluk performansı vermiştir. Bu sonuçlardan anlaşılacağı üzere eğitim aşamasındaki öğrenme tolerans aralıkları test aşaması sonuçları için önemli bir kriterdir. Inception modelinde ise Çizelge 4.4'e göre bu sefer araç hızı diğer derin öğrenme modellerinde olduğu gibi direksiyon açısından daha iyi sonuç vermiştir. Densenet derin öğrenme modeli bu deneyde en az etkilenen modeldir. Tolerans değerlerindeki farklılık Densenet'e çok fazla bir etki yapmamıştır. Farklı araştırmacıların yaptıkları çalışmaların kıyaslayabilmesi için normalde standart bir tolerans aralığı olması ve bu tolerans aralığına göre eğitim yapılması gerekmektedir. Fakat literatürde böyle bir şey bulamadığımız için bu tezde bu aralığın önemi gösterilmiştir.

Çizelge 4.4. 5 Km/s ve 6 derece tahmin doğruluğu sonuçları.

DERİN ÖĞRENME MODELLERİ	KONTROL KOMUTLARI	Tolerans 1 %	Tolerans 2 %	Tolerans 3 %	Tolerans 4 %	Tolerans 5 %
INCEPTION-V4	ARAÇ DİREKSİYON AÇISI	13	27	38	48	57
	ARAÇ HIZI	18	33	47	59	71
RESNET-152	ARAÇ DİREKSİYON AÇISI	16	32	45	55	62
	ARAÇ HIZI	23	45	60	71	80
PİLOTNET	ARAÇ DİREKSİYON AÇISI	42	62	72	78	82
	ARAÇ HIZI	55	78	88	93	96
DENSENET-169	ARAÇ DİREKSİYON AÇISI	14	26	36	44	51
	ARAÇ HIZI	15	31	43	53	61

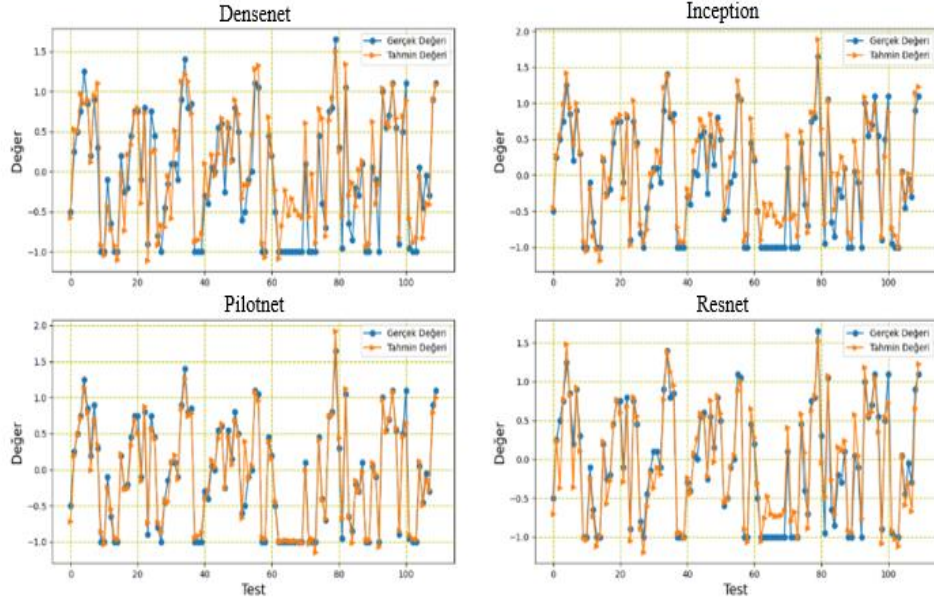
Çizelge 4.3 ve Çizelge 4.5'te ki ortalama hata ve ortalama kayıp değerlerine bakıldığında Çizelge 4.5'te ki değerlerin tüm modellerde daha düşük olduğu olduğu gözlemlenmektedir. Burada tolerans değerinin eğitim aşamasındaki etkisi görülmüştür.

Çizelge 4.5. 5 Km/s ve 6 derece toleransa göre ortalama hata ve kayıp.

DERİN ÖĞRENME MODELLERİ	KONTROL KOMUTLARI	TEST HATA ORTALAMA	TEST ORTALAMA KAYIP
INCEPTION-V4	ARAÇ DİREKSİYON AÇISI	8,12	0,061
	ARAÇ HIZI	3,93	
RESNET-152	ARAÇ DİREKSİYON AÇISI	6,25	0,037
	ARAÇ HIZI	3,11	
PİLOTNET	ARAÇ DİREKSİYON AÇISI	3,19	0,012
	ARAÇ HIZI	1,43	
DENSENET-169	ARAÇ DİREKSİYON AÇISI	11,51	0,140
	ARAÇ HIZI	4,84	

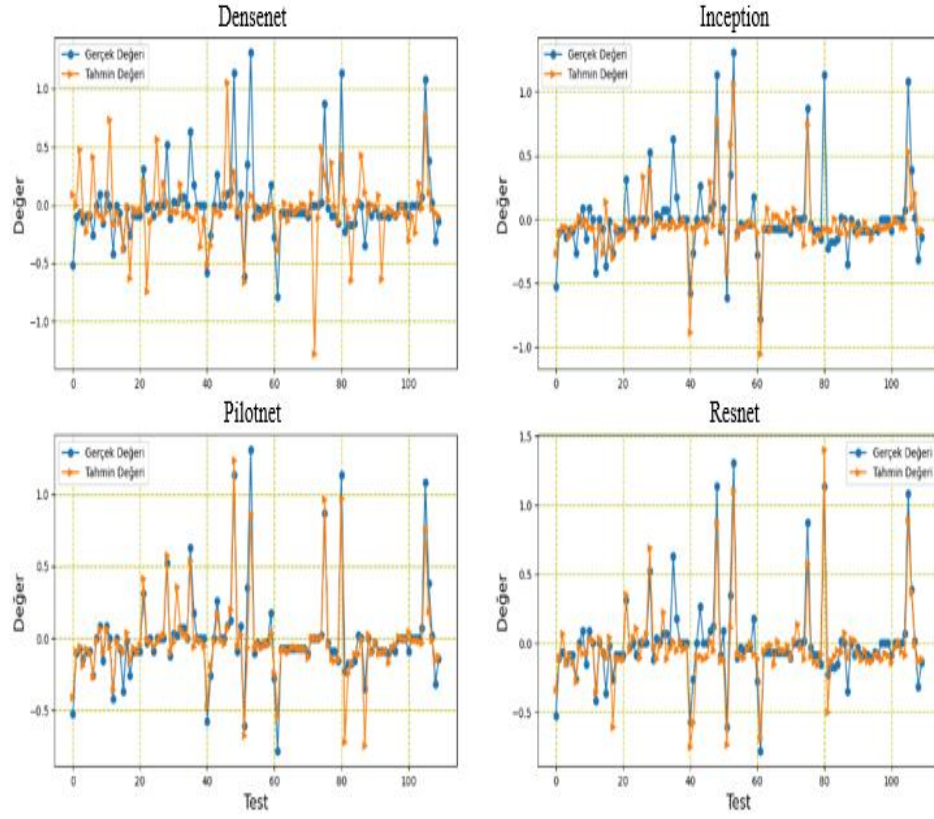
Şekil 4.11'de modellerin gerçek araç hızı, direksiyon açısı ile tahmin edilen araç hızı, direksiyon açısı değerleri grafikte verilmiştir. Hem araç hızı grafiklerinde hemde direksiyon açısı grafiklerinde PilotNet modeli dışındaki modellerin bazı test senaryolarında hatalı tahminlerde bulunduğu görülmektedir. Uçtan uca öğrenmede veri toplamının, senaryo geliştirmenin değerlendirme aşamasındaki önemi bir kez daha ortaya çıkmıştır.

Gerçek Araç Hızı - Tahmin Edilen Araç Hızı



(a)

Gerçek Direksiyon Açısı - Tahmin Edilen Direksiyon Açısı




(b)


Şekil 4.11. Tahmin – gerçek değer a) araç hızı b) direksiyon açısı.

4.4. DENEY D

Deney D ile semantik etiketlemenin şehir senaryolarında ağ performansını nasıl etkilediği incelenmiştir. Deney PilotNet modeli ile yapılmıştır. Görüntülerin etiketlenmesi ile oluşturulan kamera veri setinin kullanılması eğitim sonuçlarını kötü etkilemiştir. Off-road senaryolarda başarılı bir şekilde uygulanan yaklaşımın şehir senaryosu için uygun olmadığı görülmüştür.



(a)



(b)

Şekil 4.12. Etiketli-etiketsiz karşılaştırma a) araç hızı b) direksiyon açısı.

BÖLÜM 5

SONUÇ VE ÖNERİLER

Bu çalışmada uçtan uca sürücüsüz aracın farklı derin öğrenme modelleri kontrolü gerçekleştirilmiştir. Uçtan uca ile sürücüsüz aracın öğrenmesi için çok fazla veriye ihtiyaç vardır. Fazla verinin işlenmesi öğrenmede fazla matematik hesaplaması anlamına gelmektedir. Çalışma kapsamında DBNET veri setindeki veriler farklı önışlemlerden geçirilerek ve farklı derin öğrenme mimarileri ile eğitilerek bu önışlemler ve modeller arasından eğitim için en uygun veriler ve model tespit edilmiştir.

Yapılan çalışmada öncelikle uçtan uca sürücüsüz araç için kamera verisi, batch size boyutu ve lidar verisi belirlenmiştir. Daha sonra derin öğrenme modellerinin sadece kamera verileri ile öğrenmesi ve kamera verisinin yanına lidar verileri de kullanılarak öğrenmesi arasındaki fark incelenmiş, lidar verilerinin doğruluğa yaptığı olumlu katkı gözlemlenmiştir. Farklı derin öğrenme modelleri farklı tolerans değerleri ile eğitilip test edilerek toleransın öğrenme üzerindeki etkisi incelenmiştir. Ayrıca kullanılan derin öğrenme modelleri içinde uçtan uca öğrenme yönteminde en iyi sonuç veren model tespit edilmiştir.

Batch size 32 boyutu bu çalışma için uygun batch size olarak tespit edilmiştir. Özellikle 8 batch size boyutu hem doğruluğu düşürmüş hem de eğitim süresini iki kat arttırmıştır.

Kamera görüntülerinin kırılmasının öğrenme performanslarına etkisinin incelendiği deneylerde, gökyüzü ve etraftaki binaların kırıldığı kamera görüntüleri, bu detayları barındıran kamera görüntüleri ile aynı öğrenme performansı vermiştir. Bu nedenle bu tarz bir çalışmada kamera görüntüsünün sadece ihtiyaç olunan kısımlarının eğitimde kullanılmasının modelin öğrenimi açısından daha faydalı olduğu görülmüştür.

Lidar sensörü aracın etrafını detaylı bir şekilde taramaktadır ve her bir sahnede 700000 lidar noktası toplanmıştır. Bu taramada eğitim için faydalı olan nesnelere kadar eğitimi etkilemeyen veya olumsuz yönde etkileyen de birçok nesne bulunmaktadır. 700000 lidar noktası önce SOR filtresi ile filtrelenmiştir. Daha sonra bu noktalardan sırasıyla rastgele 32768 ile 16384 nokta seçilmiştir. Eğitim sonucunda iki farklı nokta sayısı için de aynı seviyede öğrenme performansı elde edilmiştir. Fakat eğitim süresi açısından aralarında iki kat fark gözlemlenmiştir. Bu sebeple 16384 nokta lidar kullanımının uygun olduğu tespit edilmiştir.

Bu çalışmada, ikili semantik etiketleme, off-road bir yol yerine kent ortamında toplanan bir veri seti üzerinde uçtan uca öğrenme ile denenmiştir. Sonuç olarak ise semantik etiketlemenin kent gibi karmaşık ortamlardaki uçtan uca öğrenme temelli sürücüsüz araç çalışmalarında kullanılamayacağı tespit edilmiştir.

Sürücüsüz araç direksiyon açısının eğitim grafiklerinde özellikle 0 – 50 epoch arasında bir düşme gözlemlenmiştir. Bunun nedeni araştırıldığında veri setinde özellikle direksiyon açısı verilerinde çok sıfır rakamı olduğu tespit edilmiştir. Veri setinin homojen bir şekilde ayarlanması için veri sayısı azaltılarak yeni bir veri setiyle tekrar eğitim yapılarak, problemin kısmen çözüldüğü görülmüştür.

Hem kamera verileri hemde lidar verileri ile eğitim yapılan bir derin öğrenme modelinde doğruluk anlamında gözle görülür bir değişim gözlemlenmiştir. Lidar verileri öğrenmeye olumlu katkıda bulunmuştur. Bu çalışmada uçtan uca öğrenme için kullanılan dört derin öğrenme modeli arasından en uygun modelin PilotNet derin öğrenme modeli olduğu gözlemlenmiştir.

Uçtan uca öğrenme yöntemi henüz yeni gelişim sürecinde bir öğrenme yöntemi olduğu için eğitim esnasında hiç görmediği bir senaryoda istenilen iyi sonuçları vermemektedir. Zaten literatürde de şu anda bu yöntemin en büyük dezavantajı olarak bu gösterilmektedir. Bu metod çok fazla senaryoya yani veriye ve bunları teker teker eş zamanlı olarak sürücü davranışlarına eşleyecek donanımsal gelişmişliğe ihtiyaç duymaktadır. Uçtan uca öğrenme metodu bu dezavantajından dolayı daha basit senaryoların bulunduğu off-road yollarda daha fazla tercih edilmekte olmasına

rağmen bu çalışmada kalabalık bir kent senaryosunda da özellikle PilotNet derin öğrenme modelinde kötü sonuçlar vermemiştir. Fakat metotun halen yolun başında olduğu ve gelişime ihtiyaç duyduğu Çizelge 5.1'deki sonuçlarda görülmektedir. Çizelge 5.1'de tamamen farklı senaryoların sahip verilerin bulunduğu bir veri seti üzerinden aracın doğruluk değerleri gösterilmiştir. PilotNet burada dördüncü bölümdeki deneylerin aksine en kötü sonucu veren derin öğrenme modeli olmuştur.

Çizelge 5.1. Test sonuçları.

DERİN ÖĞRENME MODELLERİ	KONTROL KOMUTLARI	Tolerans 1 %	Tolerans 2 %	Tolerans 3 %	Tolerans 4 %	Tolerans 5 %
INCEPTION-V4	ARAÇ DİREKSİYON AÇISI	11	20	27	34	40
	ARAÇ HIZI	10	13	19	25	31
RESNET-152	ARAÇ DİREKSİYON AÇISI	11	20	29	34	40
	ARAÇ HIZI	10	13	20	26	31
PİLOTNET	ARAÇ DİREKSİYON AÇISI	10	17	22	29	35
	ARAÇ HIZI	10	16	22	27	32
DENSENET-169	ARAÇ DİREKSİYON AÇISI	11	20	28	34	41
	ARAÇ HIZI	10	13	20	25	32

Sürücüsüz araçlar için derin öğrenme temelli uçtan uca öğrenme sadece umutları arttırmıştır ancak sürücüsüz araç için insanoğlunun önünde daha uzun bir yol vardır. Derin öğrenme alanındaki yapılacak her gelişme hatta geleneksel makine öğreniminin ileri taşınarak derin öğrenmenin geliştirilmesi gibi farklı bir öğrenme yönteminin geliştirilmesi ile bu uzun yolda daha fazla mesafe katedileceği düşünülmektedir.

Öğrenme tecrübeye dayalı bir fiildir ve bir makinenin öğrenmesi ancak senaryoların bulunduğu verilerle olmaktadır. Her veri, her senaryo bir tecrübedir. Bu verileri işleyecek yapay zekâ algoritması kadar bu verilerin elde edilmesi ve kullanılabilir hale getirilmesi de sürücüsüz araç gelişimini doğrudan etkileyecek çok önemli bir unsurdur. Yukarıda bahsedilen koşullarda ne kadar hızlı ilerleme olursa beşinci seviye otonom araca ulaşmak da o kadar yakın olacaktır.

KAYNAKLAR

1. Grigorescu, S., Trasnea, B., Cocias, T., and Macesanu, G., "A survey of deep learning techniques for autonomous driving", *Journal Of Field Robotics*, 37 (3 (Shalev-Shwartz et al., 2016; T. Zhang et al., 2016): 362–386 (2020).
2. Guastella, D. C. and Muscato, G., "Learning-based methods of perception and navigation for ground vehicles in unstructured environments: A review", *Sensors (Switzerland)*, 21 (1): 1–22 (2021).
3. Qinetiq, J. B., "SELF-SUPERVISED LEARNING SCHOOL OF AEROSPACE , TRANSPORT AND Autonomous Vehicle Dynamics and Control", *CRANFIELD UNIVERSITY*, (2020).
4. Yong, S. Z., Yershov, D., Frazzoli, E., Paden, B., and Cáp, M., "A Survey of Motion Planning and Control Techniques for Self-driving Urban Vehicles", *IEEE Transactions On Intelligent Vehicles*, 1 (1): 1–27 (2016).
5. Graefe, E. D. D. and V., "Dynamic Monocular Machine Vision", *Machine Vision And Applications*, 1 (4): 223–240 (1988).
6. Claudine Badue, R. G., "Self-driving cars A survey", *Expert Systems With Applications*, 27 (2020).
7. Ernst D. Dickmanns, "Vehicles Capable of Dynamic Vision", *Artificial Intelligence*, Volume 103: 1577–1592 (1992).
8. Frank E. Schneider and Dennis Wildermuth Fraunhofer, "Results of the European Land Robot Trial and Their Usability for Benchmarking Outdoor Robot Systems", *Towards Autonomous Robotic Systems*, 408–409 (2011).
9. Internet:"Sparkfun Otonom Araç Yarışması", <https://avc.sparkfun.com/> .
10. Pietro Cerri, Giacomo Soprani, P. Z., "Computer Vision at the Hyundai Autonomous Challenge", *14th International IEEE Conference On Intelligent Transportation Systems*, 777–783 (2011).
11. Broggi, A., Cerri, P., Felisa, M., Laghi, M. C., Mazzei, L., and Porta, P. P., "The VisLab Intercontinental Autonomous Challenge: An extensive test for a platoon of intelligent vehicles", *International Journal Of Vehicle Autonomous Systems*, 10 (3): 147–164 (2012).
12. Englund, C., Chen, L., Ploeg, J., Semsar-Kazerooni, E., Voronov, A., Bengtsson, H. H., and Didoff, J., "The Grand Cooperative Driving Challenge 2016: Boosting the introduction of cooperative automated vehicles", *IEEE Wireless Communications*, 23 (4): 146–152 (2016).
13. Internet: Salter, A., "7 Universities That Are Pushing the Boundaries of

Autonomous Driving", <https://www.2025ad.com/7-universities-that-are-pushing-the-boundaries-of-autonomous-driving-2021> .

14. Ni, J., Chen, Y., Chen, Y., Zhu, J., Ali, D., and Cao, W., "A survey on theories and applications for self-driving cars based on deep learning methods", *Applied Sciences (Switzerland)*, 10 (8): 1–29 (2020).
15. Internet: synopsys, "What Is an Autonomous Car?", <https://www.synopsys.com/automotive/what-is-autonomous-car.html> .
16. LeCun, Y., Muller, U., Ben, J., Cosatto, E., and Flepp, B., "Off-road obstacle avoidance through end-to-end learning", *Advances In Neural Information Processing Systems*, 739–746 (2005).
17. Ostafew, C. J., Schoellig, A. P., and Barfoot, T. D., "Visual teach and repeat, repeat, repeat: Iterative Learning Control to improve mobile robot path tracking in challenging outdoor environments", *IEEE International Conference On Intelligent Robots And Systems*, 176–181 (2013).
18. Pomerleau, D. A., "ALVINN: an autonomous land vehicle in a neural network (Technical Report CMU-CS-89-107)", *Advances In Neural Information Processing Systems*, 305–313 (1989).
19. Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P., Jackel, L. D., Monfort, M., Muller, U., Zhang, J., Zhang, X., Zhao, J., and Zieba, K., "End to End Learning for Self-Driving Cars", *ArXiv*, 1–9 (2016).
20. Gao, H. X. Y. and Darrell, F. Y. T., "End-to-end Learning of Driving Models from Large-scale Video Datasets", *2017 IEEE Conference On Computer Vision And Pattern Recognition (CVPR)*, 3530–3538 (2017).
21. Eraqi, H. M., Moustafa, M. N., and Honer, J., "End-to-End Deep Learning for Steering Autonomous Vehicles Considering Temporal Dependencies", *31st Conference On Neural Information Processing Systems (NIPS), Machine Learning For Intelligent Transportation Systems Workshop, Long Beach, CA, USA, 2017*, 1–8 (2017).
22. Yang, S., Wang, W., Liu, C., Deng, W., and Hedrick, J. K., "Feature analysis and selection for training an end-To-end autonomous vehicle controller using deep learning approach", *IEEE Intelligent Vehicles Symposium, Proceedings*, 1033–1038 (2017).
23. Hecker, S., Dai, D., and Van Gool, L., "End-to-end learning of driving models with surround-view cameras and route planners", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 11211 LNCS: 449–468 (2018).
24. Zhang, K., Niroui, F., Ficocelli, M., and Nejat, G., "Robot Navigation of Environments with Unknown Rough Terrain Using deep Reinforcement Learning", *2018 IEEE International Symposium On Safety, Security, And Rescue Robotics, SSRR 2018*, (2018).
25. Bakken, M., Moore, R. J. D., and From, P., "End-To-end Learning for

- Autonomous Crop Row-following", *IFAC-PapersOnLine*, 52 (30): 102–107 (2019).
26. Nguyen, A., Nguyen, N., Tran, K., Tjiputra, E., and Tran, Q. D., "Autonomous navigation in complex environments with deep multimodal fusion network", *IEEE International Conference On Intelligent Robots And Systems*, 5824–5830 (2020).
 27. Kahn, G., Abbeel, P., and Levine, S., "BADGR: An Autonomous Self-Supervised Learning-Based Navigation System", *IEEE Robotics And Automation Letters*, 6 (2): 1312–1319 (2021).
 28. Chen, Y., Wang, J., Li, J., Lu, C., Luo, Z., Xue, H., and Wang, C., "DBNet: A Large-Scale Dataset for Driving Behavior Learning", *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, (2018).
 29. Santana, E. and Hotz, G., "Learning a Driving Simulator", *ArXiv:1608.01230*, (2016).
 30. Geiger, A., Lenz, P., Stiller, C., and Urtasun, R., "Vision meets robotics: The KITTI dataset", *International Journal Of Robotics Research*, 32 (11): 1231–1237 (2013).
 31. Geiger, A., Lenz, P., and Urtasun, R., "Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite", *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 3354–3361 (2012).
 32. Will Maddern, Geoffrey Pascoe, C. L. and P. N., "1 Year, 1000km: The Oxford RobotCar Dataset", *The International Journal Of Robotics Research*, 36 (1): (2016).
 33. Internet: Yulia Gavrilova, "Artificial Intelligence vs. Machine Learning vs. Deep Learning: Essentials", <https://serokell.io/blog/ai-ml-dl-difference> .
 34. Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P., "Gradient-Based Learning Applied to Document Recognition", *Proc. OF THE IEEE*, (1998).
 35. Internet: ayyüce kızrak, "Lenet", <https://ayyucekizrak.medium.com/derine-daha-derine-evrişimli-sinir-ağları-2813a2c8b2a9> .
 36. Alex Krizhevsky, Ilya Sutskever, G. E. H., "Breeds Classification with Deep Convolutional Neural Network", *PervasiveHealth: Pervasive Computing Technologies For Healthcare*, 145–151 (2020).
 37. Simonyan, K. and Zisserman, A., "Very deep convolutional networks for large-scale image recognition", *3rd International Conference On Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–14 (2015).
 38. He, K., Zhang, X., Ren, S., and Sun, J., "Deep residual learning for image recognition", *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 2016-Decem: 770–778 (2016).

39. Mehta, A., Subramanian, A., and Subramanian, A., "Learning End-to-end Autonomous Driving using Guided Auxiliary Supervision", *ACM International Conference Proceeding Series*, (2018).
40. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., "Going deeper with convolutions", *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 07-12-June: 1–9 (2015).
41. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z., "Rethinking the Inception Architecture for Computer Vision", *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 2016-Decem: 2818–2826 (2016).
42. Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, A. A. A., "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning", *Pattern Recognition Letters*, 42 (1): 11–24 (2017).
43. Lee, D., Chen, K., Liou, K., Liu, C., and Liu, J., "Deep Learning and Control Algorithms of Direct Perception for Autonomous Driving", *Applied Intelligence*, 51: 237–247 (2021).
44. Islam, M. K., Yeasmin, M. N., Kaushal, C., Amin, M. Al, Islam, M. R., and Hossain Showrov, M. I., "Comparative Analysis of Steering Angle Prediction for Automated Object using Deep Neural Network", *2021 9th International Conference On Reliability, Infocom Technologies And Optimization (Trends And Future Directions) (ICRITO)*, (4): 1–7 (2021).
45. Internet: Pablo Ruiz, "Understanding and Visualizing DenseNets", <https://towardsdatascience.com/understanding-and-visualizing-densenets-7f688092391a> .
46. Wang, Y., Liu, D., Jeon, H., Chu, Z., and Matson, E. T., "End-to-end learning approach for autonomous driving: A convolutional neural network model", *ICAART 2019 - Proceedings Of The 11th International Conference On Agents And Artificial Intelligence*, 2 (Icaart): 833–839 (2019).
47. Internet: Mariusz Bojarski, Ben Firner, Beat Flepp, Larry Jackel, Urs Muller, K. Z., "End-to-End Deep Learning for Self-Driving Cars", <https://developer.nvidia.com/blog/deep-learning-self-driving-cars/> .
48. Internet: Thomson, C., "LiDAR vs Point Clouds: Learn the Basics of Laser Scanning, 3D Surveys and Reality Capture", <https://info.vercator.com/blog/lidar-vs-point-clouds> .
49. Internet: "Removing outliers using a StatisticalOutlierRemoval filter", "https://pointclouds.org/documentation/tutorials/statistical_outlier.html#background".

ÖZGEÇMİŞ

Ali ART ilk ve orta öğrenimini Kütahya'da tamamladı. 2018 yılında Uludağ Üniversitesi Elektrik Elektronik Mühendisliği Lisans programını tamamladı. 2019 yılında Elektrik Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans programına başladı. 2020 yılında beri Karabük Üniversitesinde Araştırma Görevlisi olarak çalışmaktadır.