Gezgin Robotlarda Görü Tabanlı Navigasyona Yönelik İmge Sınıflandırması

Nevin Dargut

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Ağustos 2018

Image Classification for Vision Based Navigation on Mobile Robots

Nevin Dargut

MASTER OF SCIENCE THESIS

Department of Electrical Electronics Engineering

Aug 2018

Gezgin Robotlarda Görü Tabanlı Navigasyona Yönelik İmge Sınıflandırması

Nevin Dargut

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik Elektronik Mühendisliği Anabilim Dalı
Telekomünikasyon - Sinyal İşleme Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Doç .Dr. Metin Özkan

-

Ağustos 2018

ONAY

Elektrik Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisi Nevin Dargut'un YÜKSEK LİSANS tezi olarak hazırladığı "**Gezgin Robotlarda Görü Tabanlı Navigasyona Yönelik İmge Sınıflandırması**" başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğin ilgili maddeleri uyarınca değerlendirilerek oybirliği ile kabul edilmiştir.

Danışman : Doç .Dr. Metin Özkan

İkinci Danışman : -

Yüksek Lisans Tez Savunma Jürisi:

Üye : Doç. Dr. Metin Özkan

Üye : Prof. Dr. Osman Parlaktuna

Üye : Dr. Öğr. Üyesi Muammer Akçay

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve ..... sayılı kararıyla onaylanmıştır.

Prof.Dr. Hürriyet ERŞAHAN
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Doç .Dr. Metin Özkan danışmanlığında hazırlamış olduğum "**Gezgin Robotlarda Görü Tabanlı Navigasyona Yönelik İmge Sınıflandırması**" başlıklı YÜKSEK LİSANS tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 26/09/2018

Nevin Dargut

ÖZET

Bilinmeyen bir ortamda yol takibi ya da keşif yaparken zarar görmemek, görevi tamamlayabilmek için çok önemlidir. Gezgin robotlar için orman patikaları gibi karmaşık alanlarda hareket planlaması yapmak oldukça zordur. Genellikle dış ortamda navigasyon için küresel konumlandırma sistem birimleri kullanılır. Bu birimlerin ürettiği sonuçların doğruluğu birçok koşula bağlıdır. Özellikle de bulunulan bölgenin çevre koşulları sonuç üzerinde etkilidir. Ormanlarda bağlantı problemlerine sıklıkla rastlanır. Benzer şekilde farklı sensörlerin doğaları gereği farklı limitleri bulunmaktadır. Bu sebeple navigasyon doğruluğunu arttırmak için farklı tipte sensörler birlikte kullanılır.

Bu çalışmada, mobil robot navigasyon sistemlerini desteklemek için görsel veriden yön bilgisi üretilmiştir. Güncel imge sınıflandırma teknikleri derin öğrenme temellidir. İmgeleri sınıflandırmak ve yön bilgisi elde etmek için derin yapılı modeller seçilmiştir.

Bu modeller hem mevcut bir veri seti hem de yeni oluşturulan bir veri seti ile birlikte eğitilmiştir. Etiketleme ve eğitim maliyetini son derece düşük hale getirecek şekilde, yön temelli bir veri seti oluşturulmuştur. Üç yön etiket olarak kullanılmıştır. Her yön robotun bakış açısını temsil etmektedir.

Anahtar Kelimeler: Gezgin robot, Görü tabanlı navigasyon, Konvolüsyonel ağlar

SUMMARY

Following a path or exploring an area without getting damaged is very important for completing missions, especially in unknown environments. Motion planning in complicated places, such as forest trails, can be very problematic for mobile robots. Generally global positioning system units are used for outdoor navigation purposes. The accuracy of these units depends on many factors, especially characteristics of the surroundings. Connection problems are seen very frequently on forest areas. Similarly, other sensor types have their own limitation because of their nature. Most of the sensors are used with an another type of sensor for increasing the accuracy of navigation.

In this study, direction information was produced from visual data for supporting mobile robot navigation systems. Current image classification techniques are based on deep learning. Deep structured models were chosen for classifying images and getting direction information.

The models were trained with using an existing and a newly created data set together. A direction based data set was created to make labeling and training costs extremely low. Three directions were used as labels. Each direction represents the perspective of the robot.

Keywords: Mobile robot, Vision based navigation, Convolutional nets

TEŞEKKÜR

Yüksek lisans tez çalışmam süresince kendisinden öğrendiklerim için danışmanım Doç.Dr. Metin Özkan'a teşekkür ederim.

Eskişehir Osmangazi Üniversitesi'ndeki öğrenimim süresince beni ekibin bir parçası yapan ve destekleyen Prof.Dr. Osman Parlaktuna'ya teşekkür ederim.

Yapay Zeka ve Robotik Laboratuvarı'ndan arkadaşlarım Zuher Kazanci, Alparslan Yufka'ya teşekkür ederim.

Arkadaşım Dr.Öğr. Üyesi Kemal Keskin'e tez yazım süresince verdiği destek için gönülden teşekkür ederim.

İnsanınn sevdiği işi yapması gerektiğine olan inancımı körükleyen Sinan Bubik'e teşekkür ederim.

Hayal gücüme katkılarından dolayı Jules Verne ve James Cameron'a çok teşekkür ederim.

Tez yazım süresince verdiği mangal ve moral desteği sebebiyle, Direktörüm Mustafa İskender Güvenç'e ve donanım desteği için Proline Bilişim A.Ş.'ye teşekkür ederim.

Yüksek lisans öğrenimim boyunca gösterdikleri destek ve sabır sebebiyle annem Zerrin Canik ve babam İsmail Coşkun Canik, kardeşlerim Nermin Canik ve Engin Canik'e çok teşekkür ederim.

Yüksek lisans öğrenimim boyunca yoldaşım olduğu ve kendisini tanıdığım için çok mutlu olduğum Yeşim Gürbüz'e teşekkür ederim.

Tüm hedeflerime olduğu gibi, yüksek lisans eğitimime de gösterdiği destek sebebiyle, neşemin kaynağı eşim Mesut Dargut'a teşekkür ederim.

İÇİNDEKİLER

Sayfa

ÖZET . . . . . **vi**

SUMMARY . . . . . **vii**

TEŞEKKÜR . . . . . **viii**

İÇİNDEKİLER . . . . . **ix**

ŞEKİLLER DİZİNİ . . . . . **xi**

ÇİZELGELER DİZİNİ . . . . . **xii**

1. GİRİŞ VE AMAÇ **1**

2. LİTERATÜR ARAŞTIRMASI **3**
2.1. Gezgin Robot Çalışmaları 3
2.2. Robot Navigasyonu 8
2.3. Robotlar için Bilgisayar ile Görü Çalışmaları 12
2.4. Benzer Çalışmalar 16

3. TEORİK BİLGİ **21**
3.1. Derin Öğrenme 21
3.2. Konvolüsyonel Sinir Ağları 24
3.2.1. Giriş Katmanı 24
3.2.2. Konvolüsyon Katmanı 25
3.2.3. Düzleştirilmiş Doğrusal Birim Katmanı 26
3.2.4. Havuzlama Katmanı 27
3.2.5. Tam Bağlı Katman 27
3.2.6. Düğüm Seyreltme Katmanı 27
3.2.7. Sonuç Katmanı 28

4. MATERYAL VE YÖNTEM **29**
4.1. Geliştirme Ortamı 29
4.1.1. Eğitim Bilgisayarı 29
4.1.2. Jetson TX2 Geliştirme Kartı 29
4.1.3. Caffe 30
4.1.4. DIGITS 32

İÇİNDEKİLER (devam)

4.2. Derin Öğrenme Modelleri 35
4.2.1. AlexNet 35
4.2.2. GoogLenet 37

5. BULGULAR VE TARTIŞMA 44

6. SONUÇ VE ÖNERİLER 52

KAYNAKLAR DİZİNİ 53

ŞEKİLLER DİZİNİ

Şekil		Sayfa
2.1	Shakey (Nilsson, 1969)	4
2.2	Mars Exploration Rover isimli görev için robotu Mars yüzeyinde gösteren bir çizim (NASA Facts National Aeronautics and Space Administration, 2004)	5
2.3	LS3 Legged Squad Support Systems (Boston Dynamics, 2017)	5
2.4	Terminatör 2 filminden nesne tanıma sahnesi (Cameron, 1991)	6
2.5	Görsel bölütleme ve sınıflandırma (Deepika ve Sajith Variyar, 2017)	7
3.1	Yapay Sinir Hücre Yapısı	22
3.2	Çok Katmanlı Yapı	23
3.3	Konvolüsyonel Sinir Ağı Mimarisi	24
3.4	İki Boyutlu Konvolüsyon	26
3.5	Düğüm Seyreltme	27
4.1	TX2 Geliştirme Kartı (NVIDIA, 2016)	30
4.2	Protocol Buffer yapısı ile AlexNet model katmanları ifadesi	31
4.3	DIGITS ana ekranı	32
4.4	Epoch - öğrenme hızı ilişkisi	33
4.5	Kayıp fonksiyonu - öğrenme hızı ilişkisi	33
4.6	Test imgesi	34
4.7	Digits ara katman çıktısı	34
4.8	AlexNet katmanları	35
4.9	AlexNet modeli	36
4.10	Inception modülü	37
4.11	GoogLeNet modeli (1)	38
4.12	GoogLeNet modeli (2)	39
4.13	GoogLeNet modeli (3)	40
4.14	GoogLeNet modeli (4)	41
4.15	GoogLeNet modeli (5)	42
4.16	GoogLeNet modeli (6)	43
5.1	Aynı yönde sağ, sol ve düz olacak şekilde üç farklı bakış açısı için veri toplanması	45
5.2	Veri setinin toplantığı bölge	46
5.3	Test verisinin toplandığı bölge	47
5.4	Sağ, orta ve sol yönlü görüntü örnekleri	48

ÇİZELGELER DİZİNİ

Çizelge		Sayfa
5.1	AlexNet modeli ile elde edilen test verisi sonuçları	49
5.2	GoogLeNet modeli ile elde edilen test verisi sonuçları	49
5.3	AlexNet modeli ile elde edilen veri seti 10 sonuçları	50
5.4	AlexNet modeli ile elde edilen veri seti 11 sonuçları	50
5.5	AlexNet modeli ile elde edilen veri seti 12 sonuçları	50
5.6	GoogLeNet modeli ile elde edilen veri seti 10 sonuçları	51
5.7	GoogLeNet modeli ile elde edilen veri seti 11 sonuçları	51
5.8	GoogLeNet modeli ile elde edilen veri seti 12 sonuçları	51

1. GİRİŞ VE AMAÇ

Son yıllarda grafik işlemci birimlerinde görülen gelişmelerin bir sonucu da robotik uygulamalarının daha farklı alanlarda kendilerine yer bulmalarıdır. Gerçek zamanlı işlem kapasitesinin artması ve buna imkan veren donanımların ucuzlayarak daha ulaşılır hale gelmesi ile, uzun yıllar öncesinde temelleri atılmış yapay öğrenme algoritmaları, günlük hayat uygulamalarında kullanılabilir duruma gelmiştir.

Sürücüsüz kara taşıtı ve insansız hava aracı uygulamalarının artması sonucu, daha kararlı ve farklı ortamlarda çalışabilen otonom navigasyon metotlarına ihtiyaç duyulmaktadır. Bunun için farklı sensör tipleri ile ilgili çalışmalar görülse de hem diğer sensörlere göre daha ucuz olması hem de daha zengin içerikli veri elde edilebilmesi sebebi ile kamera kullanımı çok yaygın görülmektedir. Buna bağlı olarak görü tabanlı navigasyon çalışmaları uygulamalarda öne çıkmaktadır.

Robotun hareketini planlayabilmesi, planladığı hareketi zarar görmeden ve bulunduğu ortama zarar vermeden gerçekleştirebilmesi için, öncelikle sensörler yardımı ile ortamı anlamlandırabilmesi gerekmektedir. Görü tabanlı çalışmalarda, bunun için hem nesne temelli hem de yüzey temelli çeşitli sınıflandırma yöntemleri kullanılmaktadır. İhtiyaca göre uygulamada kullanılacak yöntemler çeşitlenir. Bina koridorlarında hareket eden gezgin robot, duvar ve yer gibi geniş yüzeyleri algılayarak anlamlandırır ve navigasyonu bu yüzeyleri gözeterek gerçekleştirir. Şehir içi yollarda hareket eden bir robot ise yol, kaldırım, trafik lambası, yaya gibi nesneleri tanıması ile amacına uygun olarak hareket eder.

Sınıflandırma uygulamalarında, görsel bölütleme ve nesne tanıma faaliyetleri için gerçekleştirilen etiketleme çalışmaları, geliştirme sürecinin en maliyetli kısımlarındandır. Bunun sebebi ise; sinir ağı eğitimi için kullanılacak verilerin, bulunduğu sınıfa uygun olarak etiketlendirilmesinin büyük oranda insan emeğine dayanmasıdır. Robot navigasyonu için kullanılacak sınıfın eğitimi için, etiketlenecek nesnenin içinde bulunduğu alanın ya da doğrudan nesnenin şekilsel sınırlarının, imgeler üzerinde koordinat bilgileri kullanılır.

Özellikle ormanlık alan gibi hem görsel olarak karmaşık hem de hareket alanı kısıtlı bölgelerde sınıflandırma yapmak zorlu bir işlemdir. Hem yol, duvar gibi geniş ve düz yüzeyler olmaması hem de bulunan nesnelerin şehir içi alanlardaki kadar kolay

etiketlendirilememesi ve sınırlarının kolay olarak algılanamaması problemin zorluğunu arttırmaktadır.

Bu tez çalışmasında, ormanlık alanlarda gezgin robotlar için görü tabanlı navigasyonun güncel sınıflandırma teknikleri kullanılarak gerçekleştirilmesi için çalışılmıştır. Derin ağları kullanarak eğitilen ve yön bilgisini otomatik üreten bir uygulama gerçekleştirmek hedeflenmiştir. Etiketleme ve eğitim maliyetini son derece düşük hale getirecek şekilde yön temelli bir veri seti oluşturulmuştur. Bu veri seti ile eğitilen farklı ağların, test verileri ile denenerek başarı oranları karşılaştırılmıştır.

Tez ana hatları ile altı bölümden oluşmaktadır. Bölüm 1, tezde çalışılan problemin tanımını ve tezin amacını aktarmaktadır. Bölüm 2 içerisinde literatürde kullanılan metotlar ve yapılan çalışmalar ile ilgili yapılan detaylı inceleme aktarılmıştır. Bu metotlar ile gerçekleştirilmiş robot navigasyon çalışmalarına örnekler verilmiştir. Bölüm 3 içerisinde derin ağlar ile ilgili teorik bilgiler aktarılmıştır. Son üç bölüm yapılan uygulama ile ilişkilidir. Bölüm 4 içerisinde geliştirme sürecinde kullanılan ortam ve araçlar ile ilgili özet bilgi sunulmuştur. Ayrıca yöntemler detayları ile anlatılmıştır. Bölüm 5 içerisinde farklı yöntemlerin testleri ile elde edilen bulgular ve kıyaslama sonuçları paylaşılmıştır. Bölüm 6 içerisinde çalışma sonucunda elde edilen sonuçlar özetlenmiş ve öneriler paylaşılmıştır.

2. LİTERATÜR ARAŞTIRMASI

2.1 Gezgin Robot Çalışmaları

Gezgin robotlar, amaçları doğrultusunda farklı ortamlarda hareket kabiliyetine sahip robotlardır. Endüstriyel üretimde ve medikal sektörde kullanılan, sabit platform üzerinde, limitli bir alanda hareket eden robot kolu benzeri uygulamaların aksine; kara, su ve havada hareket edebilecek çeşitli tasarımlara sahiptirler.

Gezgin robotlar, hareket ettikleri ortamlarda, insan kontrolüne bağımlı olmadan, otonom navigasyonu sağlayabilmek için çeşitli sensörlerden edindikleri verileri değerlendirirler. Gezgin robotlar üzerinde, elektro-optik, termal, stereo kameraların yanı sıra, pusula, jiroskop, ivme ölçer, radar, lidar, gps gibi sensör ve teknolojiler kullanılmaktadır.

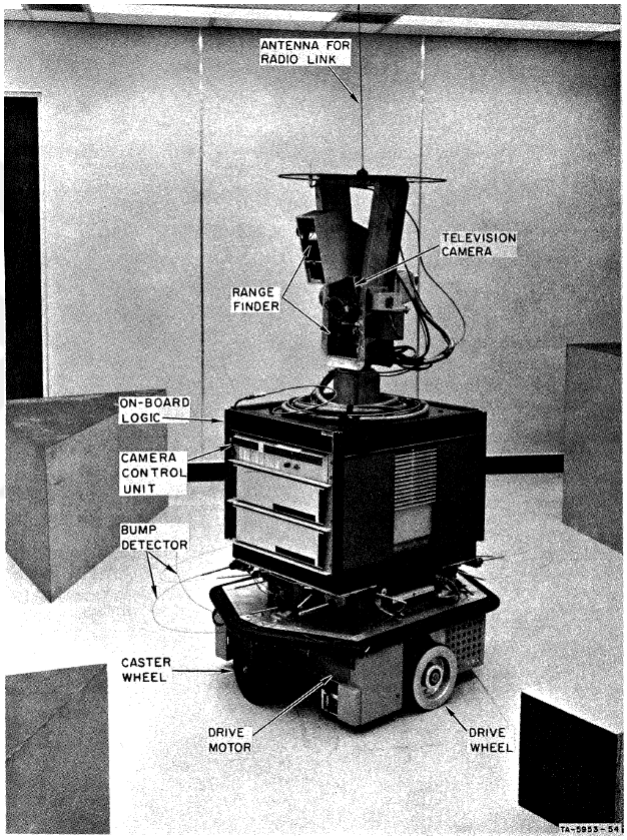
Sensör füzyonu ile, çeşitli sensör verilerinin ihtiyaca uygun birlikte kullanıldığı uygulamalar olmasının yanı sıra hem bütçesel hem de hesap maliyeti gözetilerek, tek tip sensörün kullanıldığı uygulamalar da mevcuttur. Sensör seçiminde son dönem çalışmalarında kamera ağırlıklı olarak öne çıkmaktadır.

Robotlar üzerinde, diğer sensörlere nazaran daha sık kamera tercih edilmesinin sebebi; içerik olarak tek yönlü ve sabit tipte bir veri almak yerine, daha zengin içerikli ve esnek bir veri elde edilebilmesidir. Ayrıca birçok sensör tipinden daha ucuz ve ufak boyutta kameralar üretilmekte ve bu ürünlere kolay ulaşılabilmektedir.

Görüntü üzerinde hareket, yapı, desen, renk vb. birçok bilginin ihtiyaca uygun olarak elde edilebilmesi, görsel sensörleri robot uygulamalarında öne çıkarmaktadır. Robotların kendini konumlandırması, nesneleri tanıması, tehditleri tespit edebilmesi gibi çalışmalar, ağırlıklı olarak görsel veriler üzerinden yürütülmektedir.

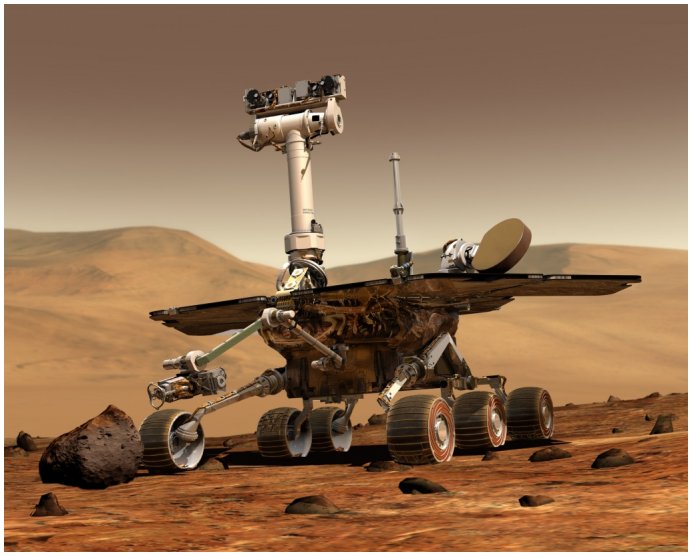
Robotun bulunduğu noktayı belirleyip konumlanması, hedef noktasına gideceği yolu hesaplayıp o doğrultuda ilerlemesi ve yolda karşısına çıkan engellerden sakınması gerekmektedir. Robotun karşılaşabileceği engeller statik veya dinamik olabilir. Hareket ettiği ortamlar robot için özel yapılandırılmış ya da doğal olabilir. Çeşitli ortamlarda, kararlı hareket sağlanabilmesi için sinir ağlarını da kullanan, görü tabanlı navigasyona yönelik birçok makine öğrenmesi algoritması geliştirilmiştir.

Görü tabanlı gezgin robotların ilk gelişmiş uygulama örneği, günümüzde Stanford Araştırma Enstitüsü (SRI) Bilgisayar Tarihi Müzesi'nde sergilenen Shakey (Nilsson, 1969) isimli robottur. Üzerinde kamera, uzaklık ve temas sensörleri, radyo link antenler ve dahili işlemciler bulunduran robot, karmaşık bir alanda hareket etmek ve çeşitli nesnelerin yerini değiştirmek gibi görevleri gerçekleştirmek için kullanılmıştır. Kompleks bir alanda hareket eden, gerçek zamanlı bir gezgin robot kontrol uygulaması olan Shakey, aynı zamanda yapay zeka tekniklerinin bütünleşik robot sistemleri üzerinde gerçekleştirildiği ilk çalışmalardan biri olarak kabul edilir. Şekil 2.1 üzerinde Shakey görülebilir.



Şekil 2.1 Shakey (Nilsson, 1969)

Altmışlı yılların sonlarında olan bu öncü çalışmadan sonra geçen elli sene içerisinde, elektronik sanayindeki gelişmelere de bağlı olarak, otonom robotların hareket alanı dünya dışına ulaşmıştır. Amerikan Ulusal Havacılık ve Uzay Dairesi (NASA) tarafından 2003 yılında Mars'a gönderilen Spirit ve Opportunity isimlerinde gezgin robotlar, üzerlerinde taşıdıkları diğer cihazların yanı sıra panoramik kameraları ile Mars yüzeyi araştırmalarına katkı sağladılar. Opportunity Nisan 2018 tarihinde hala aktif olarak görev yapmaktadır. Şekil 2.2 üzerinde Opportunity görülebilir.



Şekil 2.2 Mars Exploration Rover isimli görev için robotu Mars yüzeyinde gösteren bir çizim (NASA Facts National Aeronautics and Space Administration, 2004)

Görü tabanlı navigasyon uygulamalarını; insansız yer araçları (UGV- Unmanned Ground Vehicles), insansız hava araçları (UAV- Unmanned Aerial Vehicles), otonom sualtı araçları (AUV- Autonomous Underwater Vehicles), insansı robotlar (humanoid) ve doğadaki diğer canlılardan esinlenilen robotlar üzerinde görmekteyiz. At, eşek benzeri dört ayak üzerinde duran robot tasarımlarının yanı sıra, balıklardan ve böceklerden esinlenen kara ve suda gitmeye uygun birçok tasarım görülmektedir. Şekil 2.3 üzerinde Boston Dynamics firmasının yük hayvanlarından esinlenilen robotu görülebilir.



Şekil 2.3 LS3 Legged Squad Support Systems (Boston Dynamics, 2017)

Terminatör, West World, Battle Star Galactica gibi bilim kurgu yapımlarında uzun yıllar önce hayal edilen, insan benzeri görünüme sahip robotlar da tasarlanmaya başlanmıştır. Görünümü olduğu kadar karar alma mekanizmalarını da insana benzetmek için, bilgisayarla görü işleme tekniklerinin yanı sıra, doğal dil işleme konusunda da sinir ağları kullanılmaktadır. Hanson Robotics firması tarafından üretilen Sophia isimli robota, Suudi Arabistan hükümeti tarafından vatandaşlık verildiği duyurulmuştur. Bir robot için vatandaşlığın anlamı hala tartışılmakta olsa da önümüzdeki yıllarda insansı tepkilere sahip robotların gidebileceği noktayı işaret eden bir adımdır.

Grafik işleme birimlerinde (GPU- Graphics Processing Unit) olan gelişmelere bağlı olarak, seksenli yıllarda temelleri atılan algoritmaların gerçek zamanlı çalıştırılabilir hale gelmesi ile, robotlar bilim kurgu eserlerinde çok uzun yıllardır hayal edilen nitelikleri kazanmaya başlamışlardır. 1991 yılında gösterime giren, ünlü bilim kurgu filmi Terminatör 2'de robotun nesneleri görüntü üzerinde sınırları ile birlikte ayırt edebilmesi ve anlamlandırabilmesine benzer şekilde, bölütleme ve sınıflandırma algoritmaları ile benzer çalışmalar gerçekleştirilebilmektedir. Şekil 2.4 üzerinde filmde robotun taşıtları marka ve modelleri ile tanıdığı bir sahne görülebilir.



Şekil 2.4 Terminatör 2 filminden nesne tanıma sahnesi (Cameron, 1991)

Fabrika, hastane gibi hareket alanlarında çeşitli yer işareti ya da desenleri takip ederek hedef noktalara ulaşan robotik görü uygulamaları mevcuttur. Bu uygulamaların daha da geliştirildiği, dış ortamda yol çizgilerini takip edebilen, trafik levhalarını algılayıp, anlamlandırabilen, etrafında hareket eden ya da duran nesnelere göre planlama yapıp, uygulamaya geçebilen otonom araç çalışmaları yaygınlaşmaya, günlük hayata girmeye başlamıştır.

Otomatik park uygulamasından, sürücüsüz araçlara kadar uzanan bu çalışmalara, günümüzde birçok otomotiv firması yatırım yapmaktadır. Sürücünün kontrolünden, aracın tam otonom hareket etmesine uzanan spektrumda birçok katman bulunmaktadır. Yol ve çevre koşullarına uygun karar alarak, tüm sürüşü araçların yönettiği seviyeye ulaşılabilmiştir. Ancak çevre koşullarının ideal olmamasından kaynaklı, daha çok durumu öngörebilecek, tanıyabilecek ve buna uygun hareket edebilecek tasarımlar üzerine, her sene giderek artan sayıda çalışma yapılmaktadır.

Otonom araçlar üzerinde yer alan farklı tipte sensörler içinde, kamera uygulamaları da önemli yer tutmaktadır. Özellikle görsel nesne tespiti, alan bölütleme, yol ve trafik işareti tespiti uygulamaları Tesla, Uber, Google gibi birçok firmanın uygulamalarında görülmektedir. Şekil 2.5 üzerinde bir görsel bölütleme örneği görülebilir.



Şekil 2.5 Görsel bölütleme ve sınıflandırma (Deepika ve Sajith Variyar, 2017)

2.2 Robot Navigasyonu

Otonom navigasyon çalışmalarında robotun, tanımlı bir rotayı takip etmesi, hedef noktaya uygun rota hesaplaması ya da tanımlı bir alan içerisinde rastgele dolaşma davranışı göstermesi gibi hedefleri gerçekleştirmesi beklenir.

Hareket alanı ile ilgili, robot bilgisi açısından navigasyon üçe ayrılır:

- Harita tabanlı navigasyon,
- Harita oluşturma tabanlı navigasyon,
- Haritasız navigasyon.

Harita tabanlı navigasyonda, robot ortam haritasını bilir ve eylemlerini bu haritaya uygun olarak planlar. Harita, statik nesneleri, yer işaretlerini, ortam geometrisini ve görsel bilgileri içerecek şekilde, amaca uygun olarak tasarlanır.

Li vd.nin harita tabanlı geliştirdiği metot, akıllı tekerlekli sandalyeler için, geometrik harita tabanlı otonom navigasyon sağlar. Çok katmanlı bu haritalar üzerinde, semantik içerik ile insan- tekerlekli sandalye etkileşimi sağlanır (Li vd., 2013a). Li ve Wang ise, görü tabanlı navigasyon uygulamaları için üç boyutlu haritalandırma ile daha kesinlikli sonuçlar elde edecek bir metot önermişlerdir. Ancak özniteliklerin zengin olmadığı noktalarda, kesinlik oranlarında düşüş görmüşlerdir (Li ve Wang, 2012). Kato vd. geliştirdikleri otonom gezgin robot navigasyon sisteminde, derin pekiştirmeli öğrenme tabanlı lokal navigasyon, topolojik harita tabanlı global navigasyon önermektedirler (Kato vd., 2017).

Harita oluşturma tabanlı navigasyonda, robot çevresini keşfederek edindiği bilgiler ile bir ortam haritası oluşturur. Bu harita hem ortam keşfi amacı ile kullanılabilir hem de robot sonraki hareketlerini önceden edindiği bilgilere bağlı olarak planlayabilir.

İç ortam için Furuta vd., semantik harita tabanlı bir navigasyon metodu önermişlerdir. Geometrik haritayı, semantik haritaya çeviren metot, öğrenme için her nesnenin etiketlenmesini gerektirmemektedir (Furuta vd., 2016). Luo vd. ise, geliştirdikleri sinir ağı algoritması ile bilinmeyen bir ortamda ilerlerken çarpışmalardan kaçınan bir otonom hareket planlarken, eş zamanlı grid harita oluşturan bir metot önermektedirler (Luo vd., 2014). Eraghi vd.nin önerdiği algoritma ise, Dijkstra ve A* algoritmaları ile kıyaslandığında, en kısa yolu bulmak yerine bellek tüketimine odaklanmıştır. Yol bulma ve

bellek tüketimi dengesini gözetmeye çalıştıkları metodu, grid haritalar üzerinde uygulamışlardır (Eraghi vd., 2015).

Haritasız navigasyon, robotun ortam ile ilgili açık bir temsilini edinmeden gerçekleştirdiği navigasyon çeşididir. Diğer yöntemlere göre daha basit ve hesap maliyeti açısından daha uygun yapıdadır.

Tai vd., öğrenme tabanlı haritasız bir hareket planlayıcı önermişlerdir. El ile tanımlanmış bir öznitelik ya da ön tanıtım olmadan, haritasız bir hareket planlayıcının eğitilebilir olduğunu göstermişlerdir. Asenkron derin pekiştirmeli öğrenme metodu ile haritasız navigasyon sistemi oluşturabilmişlerdir. Bu çalışmada on boyutlu lazer uzaklık bulucu kullanılmıştır (Tai vd., 2017).

Haritalı ya da haritasız sistemlerde özel yer işaretleri de kullanılabilir. Ortamda bulunan tabelalardan anlam çıkarıldığı uygulamalar gibi, amaca uygun tabelaların da tasarlandığı uygulamalar mevcuttur. Desen, renk, yazı ve semboller ile robotun görsel olarak algılayabileceği yer işaretleri tasarlanır. Kablosuz ağ sinyallerinin de kullanıldığı uygulamalar bulunmaktadır.

Mei vd., insan yönlendirmesi için olan levhaları kullanarak, robotlar için semantik tabanlı haritasız navigasyon metodu önermişlerdir. Yazı ve yön simgesi okları kullanarak, navigasyon için yer işaretleri kullanmaya farklı bir bakışla yaklaşmışlardır (Mei vd., 2012). Lee vd. ise, gezgin robot navigasyonu için yüksek seviyeli yer işaretlerini kullanmışlardır. Yol haritası, özel yer işaretleri ile elde edilir. Kullanıcıya robotun ilerleyeceği noktaları, yer işaretleri vererek belirleme amacı güden, görsel bir sistem tasarlamışlardır(Lee vd., 2016).

Otonom navigasyon sistemlerinde kullanılan sensör verilerinin birlikte değerlendirilmesi ve hareket planının buna göre oluşturulması çalışmaları da mevcuttur. Özellikle sonar, radar ya da lidar verilerinin birlikte değerlendirildiği birçok uygulama mevcuttur.

Li vd., elektronik pusula ve kamerayı, haritalandırma çalışmaları için birlikte kullanmışlardır (Li vd., 2013b). Önerilen metot iç ortam için uygundur, dış ortamda farklı sensör entegrasyonları gerektirmektedir. Abadi vd. ise, tüm yönlü kamera ve sonar verisini birlikte kullanarak, farklı ortamlar için bir robot navigasyon metodu geliştirmişlerdir. Hem sabit hem de hareketli nesneleri algılamayı hedefleyen bu çalışma, iç ortam robotları için yapılmıştır (Hossein Bamorovat Abadi vd., 2015). Başka bir gezgin robot için görsel navigasyon çalışmasında ise Jing vd., Kinect sensörü ile elde edilen derinlik verisini, iki boyutlu lazer verisine çevirirler. Bu veri ile grid harita oluşturulur. Odometre ve jiroskop ile

konumlandırma verisi oluşturulur. Farklı tipte sensörlerin birlikte kullanılması ile konumlandırma ve navigasyon gerçekleştirilir (Xin vd., 2016a).

Otonom navigasyon çalışmaları iç ve dış ortamlarda, robotlar için özel olarak yapılandırılmış ya da doğal ortamlarda yapılmaktadır. Robotlara özelleştirilmiş yol ve işaretli bölgeler olabileceği gibi, engebeli arazi ya da düzensiz zemin olan iç ortamlarda da robotların otonom hareket etmesi gerekmektedir. Ayrıca dış ortamlarda değişken ışık kaynakları da görü tabanlı navigasyon için çözüme dahil edilmesi gereken bir noktadır.

Zhu vd., gezgin robotlar için navigasyon problemini yarı yapılandırılmış bir ortam için çalışmışlardır. Robotun hareket ettiği ortam için bazı kabuller yapıp, robotun aldığı kararları bu kabullere dayandırmışlardır. Yüzey renginin sürekli ve sabit olduğu, yol olmayan bölge renklerinin ise farklı olduğu kabulüne göre robot hareket kararını verir (Yong Zhu vd., 2011). Wang vd. ise farklı olarak, iç ortamlar için yapılandırılmamış ve engebeli bir alanda otonom robotlar için navigasyon çalışması gerçekleştirmişlerdir. Robotlar, görüntü ve derinlik bilgisini, iki boyutlu lazer sensörünü ve odometreyi birlikte kullanmışlardır (Wang vd., 2017a).

Yine iç ortam için Xin vd., dinamik ortamda otonom gezgin robot navigasyonu gerçekleştirmek ve robotun daha düzgün bir yol izleyebilmesi için Kinect sensörü ile bir görsel navigasyon sistemi tasarlamışlardır. Robot boyutuna da bağlı olarak, iyileştirilen blackwellized parçacık filtresi (Grisetti vd., 2007) algoritması ile iç ortamlar için global bir harita üretilir. Bu harita üzerinde tanıtılan global hareket temelleri ile bu hareket temelerine bağlı maliyet haritası elde edilir. Robot lokalizasyonu için adaptif monte carlo lokalizasyon metodu (Sun vd., 2013) kullanılarak, global hareket planlaması, lokal yol planlaması ile birlikte kullanılır ve robotun karmaşık ortamlarda navigasyonuna olanak sağlanır (Xin vd., 2016b).

Dış ortam için ise, Krajnik vd. gerçek zamanlı yol takibi amaçlı, tek kameralı görü tabanlı bir otonom navigasyon metodu geliştirmişlerdir. Robotun farklı ışık koşullarına da bağlı olarak görüntüde oluşan gölgeyi de hesap ederek, yürüyüş yollarında navigasyon yapması sağlanmıştır (Krajnik vd., 2015). Yine dış ortam için Li vd., görüntü bölgelerini tanıma tabanlı bir metot geliştirmişlerdir. Çalışmalarında Mean Shift, Opponent SIFt ve Bag of Words algoritmalarını birlikte kullanarak, bölge tespiti sağlanmışlardır. Tanınan bölgelere uygun olarak, robot navigasyonu sağlanmıştır (Li vd., 2016b).

Navigasyon için görsel veri ile yapılan hesaplar, robotun üzerinde gömülü bir sistem ile yapılabileceği gibi, kablosuz iletilerek ya da dış ortamdan robotun görsel verisi ile de merkezi bir noktada gerçekleştirilebilir. Son dönemde daha az güç tüketimi ile daha yüksek

işlem gücüne sahip kartların, daha ulaşılabilir ve ucuz bulunabilmesi, gömülü sistem çalışma sayısını ve başarısını arttırmıştır. Bu tez çalışmasında da eğitilen modeller, NVIDIA TX-2 kart üzerinde gömülü olarak çalıştırılmıştır.

Fen ve Zhen çalışmalarında, Kinect sensör ve DM3730 kartını üç tekerlekli robotları üzerinde kullanmışlardır. Ayrıca DSP tabanlı bir motor sürücü kartı kontrol eden kart, Kinect üzerinden aldığı veriyi gömülü olarak işlemektedir (Fen ve Zhen, 2015). Chaib vd. ise çalışmalarında, Kinect sensörü ile üç boyutlu haritanlandırma ve konumlandırma için görsel odometri tabanlı bir metot önermişlerdir. Sensörden alınan hem görsel veri hem de derinlik verisi ICP-SLAM (Iterative Closest Point- Simultaneous Localization and Mapping) ile işlenmiştir (Chaib vd., 2017). Zsedrovits vd. çalışmalarında, insansız hava araçları için çarpışmadan kaçınma için görsel tespit metodu önermişlerdir. Hem açık hem de bulutlu hava için test edilen bu algoritma gömülü olarak çalışmaktadır (Zsedrovits vd., 2011). Cigla vd. çalışmalarında, küçük hava araçları için anlık beliren nesnelere karşı çarpışmadan kaçınmak için bir metot önermişlerdir. Stereo görüşe dayanan bu yöntem, gömülü sistem üzerinde de test edilmiştir (Cigla vd., 2017).

Kara robotları gibi drone üzerinde de doğası gereği gömülü sistemler kullanılır. Robotun üzerinde verilerin değerlendirildiği sistemlerin yanı sıra, Garcia ve Ghose gibi, kullandıkları drone üzerinde alınan görsel veriyi, merkezi istasyona göndererek orada işleyen çalışmalarda mevcuttur. Garcia ve Ghose çalışmasında, merkez istasyondan gönderilen komutlara göre, drone navigasyonu sağlanır. Bu çalışmada küresel konumlandırma sisteminin çalışamayacağı, iç ortamlarda dronelar için navigasyon sağlanması hedeflenmiştir (Garcia ve Ghose, 2017).

Robotların içinde bulundukları ortamın haritasını çıkartmaları ve kendilerini konumlandırmaları, yapılan çalışmalar içerisinde önemli bir yer tutmaktadır. En sık kullanılan algoritma SLAM (Simultaneous Localization and Mapping) olarak bilinir. Robotlar, bu amaç için görsel verinin yanında, sonar, lazer, kızıl ötesi gibi birçok sensörden faydalanırlar.

Yuan vd., restoranlarda kullanılan hareketli bir servis robotu için konumlandırma kesinliğini arttırdıkları bir çalışma yapmışlardır. Yer işaretleri tabanlı sistemde, genişletilmiş kalman filtre ile robot pozisyonu hesaplanmaktadır. İç ortamda navigasyonu sağlayabilmek için kamera ve derinlik bilgisini kullanmaktadırlar (Yuan vd., 2016). Moreno-Armendariz ve Calvo, gerçek zamanlı robot navigasyonu için görsel SLAM ile engellerden kaçınma davranışı için bir metot geliştirmişlerdir. Gömülü olarak gerçekleştirilen bu sistem FPGA (Field Programmable Gate Array) tabanlı bir sistemde kodlanmıştır (Moreno-Armendariz ve Calvo, 2014).

2.3 Robotlar için Bilgisayar ile Görü Çalışmaları

Bilgisayarlı görü çalışmalarının, gezgin robotlar üzerinde uygulamaları uzun yıllardır görülmektedir. Görsel navigasyonu sağlamak için farklı tipte kamera görüntülerinden öznitelik çıkarımı, bölütleme, nesne takibi, yön ve hız kestirimi, nesne ve çarpışmadan kaçınma gibi uygulama alanlarında çalışılmaktadır. Görsel yol planlaması çalışmaları hava ve kara araçları için olduğu kadar sık görülmese de, deniz altı robotları için de çalışmalar literatürde görülmektedir.

Robotların hareket ettikleri ortamda dinamik ve statik nesnelerden kaçınması ve birçok yüzeye uzak durarak çarpışmayı önleyecek şekilde eylemde bulunması gerekmektedir. Farklı sensör verilerinin füzyonu ile yapılan çalışmalar olduğu gibi sadece görsel veri kullanılarak da çarpışmayı önleyici yöntemler geliştirilmiştir.

Cherubini vd. çalışmalarında, otonom navigasyonu görsel veri ile sağlarken, engellerden kaçınma davranışını lidar ile hesaplama yoluna gitmişlerdir. Farklı sensörlerin füzyonu engellerden kaçınma davranışı için de kullanılmaktadır (Cherubini vd., 2014). Hagiwara vd. çalışmalarında, görü tabanlı navigasyonda engellerden kaçınma davranışını görü tabanlı olarak gerçekleştirmişlerdir. Robotun yolu üzerinde bulunan insan ve nesnelerden kaçınma davranışı sergilemesini sağlamışlardır (Hagiwara vd., 2013). Chen vd. çalışmalarında, gezgin robotun engellerden kaçınma davranışı sergileyebilmesi için stereo görüş kullanmışlardır. Sonar da kullanılan çalışmada, robot kontrol algoritması bulanık mantık ile oluşturulmuştur (Chen vd., 2012). Cherubini vd. çalışmalarında, görü tabanlı navigasyon ile aynı anda nesnelerden kaçınma davranışını sergileyecek bir yöntemi test etmişlerdir. Bir yıl önceki çalışmalarında simülasyon ortamında çalıştıkları (Cherubini ve Chaumette, 2010) yöntem, yaklaşım tabanlı navigasyon için geliştirilmiştir. Dış ortam için geliştirilen bu yöntem, robotun yol alırken yayalara ve park halindeki araçlara çarpmasına engel olma amacı taşır (Cherubini vd., 2011).

Derinlik haritaları kestirimi, görsel robot navigasyonu için sık kullanılan bir yöntemdir. Özellikle SLAM (Simultaneous Localization And Mapping) algoritması ile bir çok çalışmaya rastlanmaktadır.

Kuang vd., tek kameralı SLAM (Simultaneous Localization And Mapping) algoritması uygulaması ile derinlik haritası elde etmişlerdir. Anahtar kare seçimi ile, imgeler arası öklidyen uzaklığa dayanmaktadır. Derinlik haritası kestirimi ile daha kesin sonuçlar elde etmişlerdir (Kuang vd., 2018). Hane vd. çalışmalarında, stereo görüşe sahip robotlar için navigasyon yöntemi geliştirmişlerdir. Stereo görüntüden elde edilen derinlik haritası ile, iç ortamlarda anlık harita üretme ve yüzey belirleme çalışması da yapmışlardır (Hane

vd., 2011). Xiong vd. çalışmalarında, üç boyutlu derinlik haritaları tabanlı tekerlekli robot kontrolü için bir yöntem önermişlerdir. Görü ve derinlik bilgisini sensörden alan robot, derinlik haritasındaki hatayı minimize ederek hedef noktaya ulaşmayı hedeflemektedir (Xiong vd., 2017).

Ortam ve nesneler ile ilgili bilgi edinmek, nesneleri tespit etmek ve takip etmek için özniteliklerin kullanımı görsel navigasyon için yaygın bir yöntemdir. Farklı algoritmalar ile elde edilen öznitelikler, yapılan çalışmaya göre farklı amaçlar ile kullanılabilir.

Li vd. çalışmalarında, Monte Carlo örneklemesi ve görsel öznitelik algısına dayanan bir robot navigasyon yöntemi geliştirmişlerdir (Li vd., 2015). Ryu vd. çalışmalarında, tek kamera ile çoklu görüşü kullanarak gezgin robotlar için öznitelik tespiti metodu için bir yöntem önermişlerdir. İç ortam için geliştirilen bu yöntem de görsel SLAM kullanılmıştır (Ryu vd., 2008). Martinson ve Yalla çalışmalarında, robotlar için konvolüsyonel sinir ağlarını (CNN) kullanarak gerçek zamanlı insan tespiti yöntemi önermişlerdir. Öz nitelik tabanlı olan bu yöntem, öznitelik katmanlı bir sınıflandırıcı kullanmaktadır. Gerçek zamanlı test ettikleri sistemi, farklı grafik işlemci birimleri (GPU) ile de test etmişlerdir (Martinson ve Yalla, 2016).

Huang vd. çalışmalarında, SURF (Speed UP Robust Features) tabanlı bir nesne takip algoritması kullanmışlardır. Gezgin robot üzerindeki bir web kamerası ile alınan görüntü üzerinde nesne takibi yüksek bir kesinlikle yapılabilmektedir (Huang vd., 2012). Gupta vd. çalışmalarında, SURF (Speed UP Robust Features) tabanlı insan takibi metodu önermişlerdir. Gezgin robotların insan takib, amacı ile gerçekleştirilen bu çalışma, zamanla nesne modelinin güncellenmesine dayanmaktadır (Gupta vd., 2015). Shene vd. çalışmalarında, gezgin robotlar için SURF (Speed UP Robust Features) tabanlı bir görüntü stabilizasyon metodu önermişlerdir. Öznitelik kullanımının farklı bir alanda kullanımına bir örnek olarak gösterilebilir (Shene vd., 2016).

Kim vd. çalışmalarında, dinamik nesne takibi için, görsel öznitelik füzyonu metodu önermişlerdir. Gezgin robotlarda, optik akış verisinin de kullanıldığı çalışmada, Camshift (Continuously Adaptive Mean Shift) algoritması tercih edilmiştir (Kim vd., 2017).

Robot navigasyonu çalışmalarında tek kameralı yaklaşımlar olduğu gibi, stereo kamera ile özellikle derinlik bilgisinin katacağı fayda düşünülerek de çalışmalar yürütülmektedir.

Zhang vd. çalışmalarında, tek kameralı görsel navigasyon için bir yöntem önermişlerdir. Tarım arazisi gibi ortamlarda, koridor tipi alanlar için tek kameralı bir

yaklaşım geliştirmişlerdir (Zhang vd., 2012). Chang vd. çalışmalarında, gezgin robotlar için tek kameraları bir görsel navigasyon yöntemi önermişlerdir. Yol bölgesi ve sınırlarının hesabı ile robot, iç ortam ve dış ortamda yol üzerinden ilerleme davranışı gösterir (Chang vd., 2012). Soltani vd. çalışmalarında, gezgin robotlar için görsel navigasyonu stereo kamera ile gerçekleştiren bir yöntem önermişlerdir. Yapılandırılmamış alanlarda çalışması için geliştirilen sistemde, dış ortam testleri gerçekleştirilmiştir (Soltani vd., 2012).

Görsel odometri, navigasyon çalışmaları altında popüler bir araştırma konusudur. Gezgin robotlar üzerinde lidar, radar gibi farklı sensör uygulamaları ile birlikte kamera uygulamaları da görülür.

Delgado vd. çalışmalarında, gezgin robotlar için görsel odometri metodu önermişlerdir. SIFT (scale invariant feature transformation algorithm) algoritması ile görüntünün işlendiği çalışmada stereo görüntü tercih edilmiştir (Delgado vd., 2011). Haifeng vd. çalışmalarında, optik akış tabanlı bir görsel odometri metodu önermişlerdir. Tek kameralı sistemde, RANSAC (Random sample consensus) yaklaşımı tabanlı bir odometri mevcuttur (Li vd., 2016a).

Optik akış, canlıların görüsünden ilham alınarak oluşturulan bir bilgisayarlı görü metodudur. Yapılan kabuller ile iki imge arasındaki özniteliklerin eşleşmesi ile veri elde etmeye dayanır. Nesnelerden kaçınma, hareketli nesneyi yanıma, çarpışmadan kaçınma gibi uygulamalar ile gezgin robot navigasyonu çalışmalarında sıkça kullanımına rastlanır.

Wang vd. , optik akışı yol navigasyonu için kullanmışlardır. Optik akış çıkarımından sonra, SURF (Speed-up robust features) algoritması ile iyileştirme gerçekleştirmektedirler (Wang ve Dong, 2016). Wang ve Zhao çalışmalarında, optik akışı yüzey tespiti için kullanmışlardır. Optik akış hesabına oldukça sıkı bir şekilde bağlı olan metot, mobl robotlar için navigasyon amacı ile kullanılır (Zhongli Wang ve Jie Zhao, 2011). Liau vd. çalışmalarında, metrik olmayan navigasyon için optik akışı kullanmışlardır. Gezgin robot navigasyonunu iç ortamda gerçekleştirmeyi hedefleyen çalışma, görüntünün dikey kolonlara ayrılıp, optik akış sonucuna uygun bu alanlar arasında hareket bölgesi seçilmesine dayanır (Liau vd., 2012).

Constante vd., evrişimsel sinir ağları (CNN, Convolutional Neural Networks) tabanlı, görsel odometri kestirimi üzerine yaklaşımlarını yayınlamışlardır. Ardışık imgelerden çıkarılan optik akış yoğunluk bilgisinden beslenen evrişimsel sinir ağları, daha fazla görsel bilginin türetilmesine olanak verir. Çıkartılan bu görsel bilgiden elde edilen yeni detayları kullanan, tam bağlı sinir ağı katmanları, imgeden imgeye bir kestirime olanak tanır (Costante vd., 2016). Görsel navigasyonda, yüksek performanslı lokalizasyon için

görsel odometri kestiricilerinde öğrenme üzerine derin ağlar konusunda bu tip çalışmalar yapılmaktadır.

Nesne tespiti robotların eylemlerinde alacağı kararlar için de kullanılmaktadır. İnsan tespiti ağırlıklı olmak üzere, tabela, yol, yol çizgisi, kaldırım, bisiklet gibi çeşitli sınıflar çalışmalarda görülmektedir.

Zhang vd. çalışmalarında, servis robotları için nesne tespiti ve tanıma için bir yöntem önermişlerdir. Derin öğrenme temelli olan yöntem NVIDIA TX1 üzerinde tasarlanmıştır (Zhang vd., 2017). Hernandez vd. çalışmalarında, gezgin robot üzerinde çalışan gerçek zamanlı nesne tanıma algoritmasına belirsizlik kestirim modeli uygulamışlardır. Verinin çok düzgün elde edilemediği ortamlar düşünülerek yapılan çalışmanın, bölütlemeli navigasyon sistemleri için de faydalı olabileceği düşünülmektedir (Hernandez vd., 2017). Zhong vd. çalışmalarında, nesne tanıma ve haritalandırmayı Detect-SLAM adını verdikleri yöntem ile gerçekleştirmektedirler. Hareketli nesnelerin filterelendiği yöntemde, nesne tanımanın ardından SLAM modülü devreye girer (Zhong vd., 2018).

Görsel bölütleme çalışmaları, daha eski tarihli çalışmalarda geniş yüzey tespiti için kullanılırken, daha güncel çalışmalarda nesne sınıflandırmanın ön adımı olarak görülmektedir. Gelişen işlemci imkanları ile gerçek zamanlı ya da analiz amaçlı geriden işleme yapılan birçok çalışmaya rastlanmaktadır.

Lin vd. çalışmalarında, tekerlekli bir robot için dış ortamda navigasyon için bir yöntem önermişlerdir. Derin konvolüsyonel sinir ağları temelli yöntem ile, görsel bölütlemeden faydalanılarak otonom navigasyon gerçekleştirilir (Lin vd., 2017a). Chacra vd. çalışmalarında, KITTI veri setini kullanarak yol bölütlemesi çalışması gerçekleştirmişlerdir. Otonom araçlar için yapılan bu çalışmada, gerçek sokak görüntüleri üzerinde yol çıkarımı gerçekleştirilmiştir (Chacra ve Zelek, 2016). Wang vd. çalışmalarında, konvolüsyonel sinir ağlarını kullanarak, sokak görüntüleri üzerinde yol bölütlemesi gerçekleştirmişlerdir (Wang vd., 2017b).

2.4 Benzer Çalışmalar

Son birkaç yılda droneların ucuzlaması ve daha kararlı çalışabilmesi ile birlikte, görüntü alma, devriye gezme gibi görevler için sıklıkla tercih edilir hale gelmişlerdir. Droneların da kara araçları gibi otonom olarak, farklı ortamlarda navigasyonu için çalışmalar artarak devam etmektedir. Dronelar üzerinde farklı tipte kamera ve sensörlerin birlikte kullanıldığı çalışmaların yanı sıra, hem bütçesel maliyet gözetilerek hem de hava da kalma süresi ağırlıkla da ilişkili olduğundan sadece kamera ile navigasyon sağlamayı hedefleyen farklı sistemler bulunmaktadır.

Munguia-Silva ve Martinez-Carranza, otonom uçuş için tek kamera kullanan SLAM için bir çalışma yapmışlardır. Gerçek zamanlı optik akış tabanlı derinlik kestirimi ve derinlik sınıflandırmasını bir drone üzerinde yapmaya olanak sağlayan bir algoritma önermişlerdir. Derin öğrenme ile derinlik kestiriminin kesinliğini arttırmayı hedeflemişlerdir. Hesaplanan optik akış vektör büyüklükleri, derinlik sınıflandırılması için kullanılmıştır (Munguia-Silva ve Martinez-Carranza, 2018).

Alvarez vd., quadratorlar için nesnelerden sakınma davranışını tek kamera ile gerçekleştirmek üzerine yaklaşımlarını yayınlamışlardır. Derinlik haritası çıkartılıp, bu haritanın iki boyutlu taranması ile navigasyon için uygun yol noktaları belirlenir. Quadrator, lokal olarak çarpışmasız gördüğü noktaları belirleyerek ilerler (Alvarez vd., 2016).

McGuire vd., iç ortamda stereo kamera kullanarak, engellerden kaçınma davranışı gösteren ve otonom navigasyon yapan ufak boyutlu bir drone sistemi geliştirmişlerdir. Ufak boyutlu gömülü sistem üzerinde, kısıtlı işlem gücü ile, yüksek verimlilikli çalışacak, Edge-FS algoritmasını önermektedirler. Bu metot ile hız ve derinlik bilgisi elde edilmesini önermektedirler. Optik akış ve stereo uyumsuzluğu, kenar dağılımları üzerinden hesaplayan sistem, stereo tabanlı uzaklık kestirimlerini, optik akışı ölçeklendirmek kullanır. 4x4 metre boyundaki bir oda da engellerden kaçınma davranışını test etmişlerdir. Engellerden kaçınma kısmı üzerinde geliştirme yapılması gerekliliğine vurgu yapmışlardır (McGuire vd., 2017).

Zhu vd., hedef odaklı görsel navigasyon için bir derin pekiştirmeli öğrenme yapısı önermektedirler. İç ortamlarda, daha az eğitim verisi ile çalıştığı öne sürülen yapı, detay eşleştirme ya da ortamın üç boyutlu yeniden yapılandırmasına ihtiyaç duymamaktadır. AI2-THOR (The House Of inteRactions) adı verilen simülasyon yapısını geliştirmişlerdir. Bu ortam aracılığı ile gerçekçi iç ortam sahnelerinde yüksek ya da alt seviyeli etkileşimli testleri gerçekleştirebilektedirler (Zhu vd., 2017).

Hui vd., yüksek gerilim iletim hatları denetiminde kullanılmak üzere otonom navige olan insansız hava araçları ile ilgili bir çalışma yayınlamışlardır. Hava aracı üzerinde NVIDIA firmasına ait TX2 kartını kullanmışlardır. Kule tespiti için de hızlı bölge tabanlı evrişimsel sinir ağlarını kullanmışlardır (Hui vd., 2017).

Orman gibi sık ağaçlık alan ve şehir içi yollara nazaran daha düzensiz olan patika yollarda hem drone hem de kara robotları için çalışmalar görülmektedir. Bu tez konusunda da orman içi patika yollarda navigasyon için imge sınıflandırılması yapılması hedeflenmiştir.

Zhilenkov vd. çalışmalarında, ağaçlı patika yollarda otomatik drone navigasyonu için geliştirdikleri metodu sunmuşlardır Arama-kurtarma çalışmalarında drone kullanımı için önerdikleri metot, derin öğrenme ve konvolüsyonel ağları kullanarak, ağaçlı alanlarda ilerlenebilecek patika bulmaya dayanır. Sınıflandırma ile otonom navigasyon sağlanır (Zhilenkov ve Epifantsev, 2018).

Smolyanskiy vd., TrailNet adını verdikleri bir derin sinir ağları modelini yayınlamışlardır. Orman içinde bulunan patika yollarda, yol veya orman şeklinde bölütleme yaparak çalışan bu model, aynı zamanda görsel odometri ve nesne tespiti algoritmaları ile birlikte, bir drone üzerinde NVIDIA TX1 kartı üzerinde gömülü olarak çalışmaktadır. Ayrıca PX4FLOW isimli bir optik akış sensör verisi de bu kart üzerinde değerlendirilmektedir (Smolyanskiy vd., 2017).

Giusti vd., orman patikaları için tek imge üzerinden, görsel yön tayini yapmaya olanak verecek bir derin sinir ağı modeli tasarlamış ve eğitmişlerdir. Gerçek ortam görüntüleri ile eğitilen bu model, bir quadrotor ile dış ortam testlerini gerçekleştirmiştir. Yol ve orman şeklinde bölütleme yapan bir derin sinir ağı yapısı, denetimli imge sınıflandırma ile çalıştırılmaktadır (Giusti vd., 2016).

Robot navigasyonu için sinir ağlarını farklı şekilllerde kullanmayı tercih eden çalışmalar literatürde görülmektedir. Özellikle ağların derinleşmesi ve hata oranlarının azalması ile konunun popülerliği daha da artmıştır.

Dionisio-Ortega vd. çalışmalarında, insansız hava araçlarının orman benzeri alanlarda görsel veri ile uçusunu sağlamak için geliştirdikleri yöntemi sunmuşlardır. Küressel konumlandırma sistemi ile hareket etmenin imkanı olmayan bu alanlarda nesnlere çarpmadan ilerlemek operasyonun önemli bir parçasının oluşturur. Alexnet yapısını kullanan sistem için ayrıca Gazebo' da simülasyon çalışması da yapılmıştır. AlexNet' in geliştirilmesi ile elde edilen derin sinir ağı, çıktı olarak üç mesafe bilgisi verir. Açık alan,

yakın nesne ve çok yakın nesne şeklinde olan bu sınıflara göre, robot hareketini düzenler (Dionisio-Ortega vd., 2018).

Jung vd. çalışmalarında, derin öğrenme kullanarak iç ortamda otonom navigasyon sağlamak için bir metot önermişlerdir. Tüm görsel veri, gerçek zamanlı olarak robot üzerinde bulunan NVIDIA Jetson TX2 kart ile yapılır. Testleri iç ortamda drone yarışı amaçlı oluşturdukları, droneların içinden geçmesi gereken kapıların olduğu bir test ortamında gerçekleştirirler. VGG-16-based SSD ile AlexNet' e göre daha yüksek bir tespit oranı aldıklarını yayınlamışlardır (Jung vd., 2018).

Huang vd. çalışmalarında, otonom drone navigasyonu için sahne tespitini, yer işaretlerine dayanan bir yöntem ile gerçekleştirirler. Çalışmada ilginç olan noktalardan biri de araçların plakalarını tespit edip, otomatik plaka okumanın çalışmanın bir parçasını oluşturmasıdır.Hem aracı hem park yerini hem de araç plakalarını sistem otomatik tanıyabilmektedir (Huang vd., 2017).

Khalilullah vd., tek kameralı, derin öğrenme tabanlı bir robot navigasyonu metodu önermişlerdir. Gerçek zamanlı olan bu yaklaşım, şehir içi dar yollar için sürüş yapılan yol bölgesinin tespitini hedeflemektedir. Deep Belief Neural Network (DBNN) isminde geliştirdikleri ağ ile kendi topladıkları veri seti ile eğitim gerççekleştirmişlerdir. Navigasyon esnasında kameradan alınan imge, parlaklık sabit bir formata dönüştürülür. Ardından ağa girdi olarak verilen imgeden, yol detayları katman katman tespit edilir. Test için kullanınlan tekerlekli robot, tespit edilen yol sınırları içinde hareket eder. Düşük maliyetli lazer mesafe bulucular ile şerit ve nesne tespiti mümkün olmadğından, sadece görüntü verisi ile çalışmayı hedeflemişlerdir. Çalışmalarını geliştirme amaçlı, sınır tespitindeki hatalarda pekiştirmeli öğrenme kullanımını ve hedef yönelimli navigasyonu önermektedirler (Khalilullah vd., 2017).

Chen vd., tek kamera SLAM ve çoklu nesne takibini, karmaşık ortamlarda daha gürbüz statik bölütlenmiş haritalar elde etmek için birlikte kullanmışlardır. Çalışma kompleks ve dinamik sahneler olan şehir içi caddelerinden toplanan bir veri seti ile denenmiştir. Önerilen metot hareketli nesneleri ayrıştırmak ve optimizasyon için sabit nesneleri belirlemek için kullanılır. Sistem, güncel evrişimsel sinir ağları ile nesne tespiti ile olası hareket eden nesnelerin sahneden ayrıştırılabilmesinden yararlanır. Ardışıl imgeler üzerinde tek kamera kullanan SLAM ile eşleştirme yaparak, çoklu nesne takibi gerçekleştirilir. Bu takipçiler ile, bölütleme yapabilmek için dinamik nesneler ve statik ortam ayrıştırılabilir. KITTI ve RobotCar veri setleri geliştirme amacı ile kullanılmıştır (Chen vd., 2017).

Hu vd., nesne ve yayalardan kaçınmak için öğrenme tabanlı bir yaklaşım önermişlerdir. Hareket kararları ile etiketlenen görüntüler ile yayalardan kaçınma ve yol takibi için iki derin öğrenme ağı eğitilmiştir. Bu yaklaşımda statik nesneler için ultrasonik sensör kullanına gidilmiştir (Hu vd., 2017).

Gezgin robotlar için sınıflandırma metolarının kulanımı yaygın olarak görülmektedir.Nesnelerdan kaçınma amacı davranışı çalışmaları, günlük hayatta ihtiyacın artmasına paralel olarak artmıştır.

Di Fava vd. iç ve dış ortamlarda devriye gezme görevini gerçekleştirecek, otonom gezgin robot navigasyon uygulaması üzerinde çalışmışlardır. İki katmanlı bir yapı kullanılan sistemde, yüksek seviyeli katman görsel verinin işlenmesi ile yol tespiti ve devriye gezilen yol üzerinde hareketli nesne ve insan tespiti gerçekleştirmektedir. Düşük seviye katmanda ise engellerden kaçınma ve ara nokta takibi ile navigasyon çalışması gerçekleştirilmiştir. MOG (Mixture of Gaussians, Stauffer ve Grimson, 1999) metodu ile elde edilen arka plandan çıkarılan hareketli nesne gezingeleri Kalman filtre ile takip edilmiştir. Yol tespiti ise, SCARF (Supervised Classification Applied to Road Following, Crisman ve Thorpe, 1993) çalışmasının geliştirilmiş bir uygulaması ile yapılmaktadır. SCARF, Bayesyen bir sınıflandırma metodu kullanarak, her piksel için yol yüzeyi olma olasılığını hesaplar (Di Fava vd., 2015).

Schaub ve Burschka, stereo akışı kullanarak yeni bir hız kestirim metodu önermişlerdir. Kara araçları için geliştirdikleri bu metot ile, derinlik yapılandırmasını ve nesne hız gözlemini daha sağlam sonuçlu gerçekleştirmek hedeflenmiştir. Tek imge noktalarından yapılan bu çalışmada, hem nesne hem kamera hareketli olabilir. Kullanım alanları, dinamik ortamlarda hareket planlaması ve engelden sakınma davranışıdır (Schaub ve Burschka, 2017).

Lin vd., derin evrişimsel sinir ağları ile robotun önünde bulunan yöl bölgelerini tanımak ve robotun kontrolü için bulanık mantık tabanlı bir kontrolcü önermişlerdir. Robotun otonom şekilde yol üzerinde hareket etmesi ve nesnelerden kaçınması için testler gerçekleştirmişlerdir. Çalışma sonuçaları tek kameradan da navigasyon yapılacbileceğine dair sonuçlar sunmuştur. Dış ortam için tekerlekli robotlara yönelik bu çalışma da piksel bazında bölütleme kullanılmıştır (Lin vd., 2017b).

Deepika ve Sajith Variyar, evrişimsel sinir ağları ve bilgisayarla görü tekniklerini birlikte kullanarak, otonom araç navigasyonu için nesne sınıflandırma ve tespit tekniklerini uygulamışlardır. Önerilen metot, SegNet ardından nesne tespiti algoritması kullanımını önerir (Deepika ve Sajith Variyar, 2017). SegNet, çoklu sınıflı piksel tabanlı bölütlemesi

için bir derin dekoder-enkoder mimarisidir. Cambridge University Computer Vision and Robotics Group tarafından geliştirilmiştir. Dört katman enkoder ve bunları takip eden uyumlu dekoder katmanlarını içerir (Badrinarayanan vd., 2017).

Xin vd., robot yol planlaması için derin pekiştirmeli öğrenme tabanlı bir metot önermektedirler. Robotun, el ile işaretlenmiş ya da eşleştirme gerektiren özniteliklere ihtiyaç duymadan, uygun hareketi doğrudan görsel algısından elde etmesini hedeflemektelerdir. Öncelikle Q-network (DQN) adındaki derin ağ, robotun durum-hareket değer fonksiyonuna yaklaşak şekilde tasarlanmış ve eğitilmiştir. Her olası robot hareketi ile ilişkili Q değeri DQN tarafından belirlenir. Bu ağa verilen girdi, üzerinde öznitelikler çıkartılmayan RGB imgedir. Sonuç olarak, hareket seçim stratejisine uygun olarak, en uygun anlık en iyi hareket seçilir (Xin vd., 2017).

Kim vd., otonom gezgin robot navigasyonu için baştan uca derin öğrenme temelli bir yaklaşım önermektedirler. Geleneksel yaklaşımlar robot navigasyonu ya da yol planlaması için lokalizasyon, navigasyon ve hareket planlaması gibi işler için çoklu ve kompleks algoritmalar önermektedirler. Görsel veriden öznitelikleri çıkartmak, bu özniteliklerden anlık pozisyonu belirlemek ve bu veriye uygun hareketin sağlanacağı bir model eğitmek gerekmektedir. İnsan için de geçerli olduğunu öne sürdükleri, global haritayı bilmeden, lokal sahneye bakarak, sadece görsel veriden elde edilen sonuç ile robotun yönlendirmesini sağlamayı hedeflemişlerdir. Modelleri hız ve yön bilgisini doğrudan üreterek, robotu hareket ettirmektedir. ROS (Robot Operating System) ve Caffe tabanlı CNN kullanmışlardır (Kim vd., 2018).

3. TEORİK BİLGİ

3.1 Derin Öğrenme

Geçmiş yıllarda popüler olan klasik sınıflandırma tekniklerinin kullanımı için öncelikle öznitelik vektörünün çıkartılması gerekmektedir. Ayırt edici nitelikleri belirleyen bu vektörü oluşturmak, hem zaman alan hem de uzmanlığa ihtiyaç duyulan, zahmetli bir süreç gerektirir. Ayrıca yapılan çalışmalar uygulamaya bağımlıdır.

Derin öğrenme konseptinin popüler hale gelmesi ile birlikte, senelerdir üzerinde çalışılan sınıflandırma, nesne tanıma, bölütleme gibi alanlarda büyük bir ilerleme görülmüştür. Daha düşük hata oranları ile sınıflandırılma yapılabilmesinin yanı sıra ham verinin doğrudan işlenebilmesi gibi avantajlar da görülmektedir. Bu metotların bulunması ve akademik yayınlarda görülmesi uzun yıllar öncesinde olsada, son bir kaç yıl içerisinde uygulamalarda diğer yöntemlere göre ön plana çıkmışlardır. Bunun sebebi yüksek boyutlu verileri işleyebilecek donanımsal yapıların gelişmesiyle ilişkilidir.

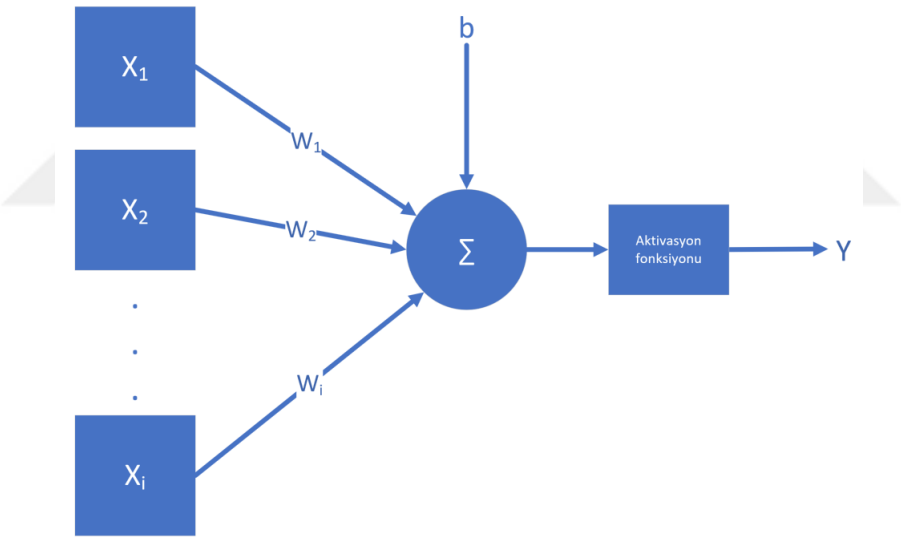
Bellek hafızası ve işlemci kapasitesi bu metotların çalıştırılmasında büyük önem taşımaktadır. Örneğin 30,000 adet görüntü içeren bir veri setinden eğitim verisi oluşturulurken, 256x256 piksel boyutunda, renkli ve 8 bit derinliğinde görüntüler için 256x256x3x30000 hesabının sonucu olarak 5,898,240,000 bayt bellek hafızasına gereksinim vardır. Paralel işleme ile daha hızlı sonuç alınacağı için bu modellerin eğitimi için ağırlıklı olarak grafik işlemci birimleri kullanılır.

Yapay sinir ağları, insan beyninden ilham ile oluşturulan bir teknolojidir. Biyolojik yapının bir taklidi olarak olarak doğan bu teknoloji, sinir sisteminin çalışma şekline benzetilerek oluşturulmuştur. Sinir hücreleri olan nöronların birbiri ile olan bağı ile oluşan ağlar, öğrenme ve bellekte tutma gibi yetenekleri doğururlar. Bu bağların düzenlenmesi ile öğrenme mümkün hale gelir. Bu süreci taklit eden yapay sinir ağları ile insan öğrenme sürecine benzer şekilde, eğitim ile bağlar yeniden düzenlenerek, bağlantı ağırlıkları optimizasyonu ile öğrenme mümkün hale gelir.

İnsan sinir hücrelerinden esinlenilen yapay sinir ağının temel parçası perseptron (3.1)'de görülen fonksiyon ile ifade edilir. b bias değerini ifade etmektedir. W ağırlık parametresidir. y, sisteme girdi olarak verilen x'e bağlı sonuç değerini ifade eder.

$$y = \sum_{n=1}^{n} W_i x_i + b \tag{3.1}$$

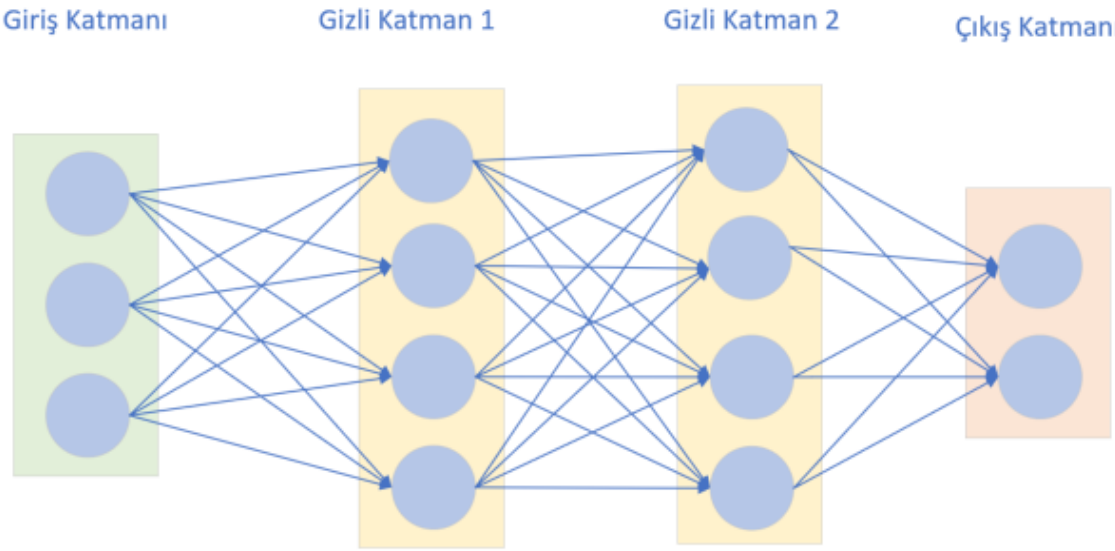
Yapay sinir ağları, derin öğrenme modellerinin temelini oluşturur. Derin öğrenme modelini oluştururken amaç, katmanlar arasında bağların düzenlenmesi ve en iyi sonucu verecek bias ve ağırlık parametrelerinin elde edilmesidir. Şekil 3.1 üzerinde yapay sinir hücre yapısı görülmektedir. Sistem girdilerinin ağırlıklandırılmış değerleri ve bias değerinin toplamı, aktivasyon fonksiyonu ile çıkış değerini üretir. Aktivasyon fonksiyonu girdinin karşılığında üretilecek çıktıyı belirleyen, genel olarak lineer olmayan bir fonksiyondur.



Şekil 3.1 Yapay Sinir Hücre Yapısı

Şekil 3.2 üzerinde çok katmanlı ağ yapısı görülmektedir. Bu örnekte iki gizli katman ve çıkış katmanı toplam on adet nöron bulundurur. Girişten çıkışa otuz altı adet bağlantıdan gelen ağırlık değeri ve on adet bias değeri bulunmaktadır. Bu çok katmanlı yapıda, toplam kırk altı adet değerin model eğitimi ile öğrenilmesi gerekmektedir.

Şekil 3.2 üzerinde de görüldüğü şekilde aynı katmandaki nöronlar, birbirleri ile ilişkili değildir. Bilgiyi çıkış ya da bir sonraki katmana aktarırlar.Art arda katmanlarda



Şekil 3.2 Çok Katmanlı Yapı

nöronlar farklı seviyelerde birbirlerini etkileyerek, öğrenme oranını belirleyen bir şekilde aktarım gerçekleştirirler. Etkileme oranı, ağırlık değerleri ile ilişkilidir.

Eğer önceden eğitilen bir modelin ağırlık bilgileri mevcut değil ise, değerler negatif ve pozitif olarak rastgele dağılımla atanır. Sıfır değeri verildiğinde öğrenme gerçekleşmeyeceğinden, bu durumdan kaçınılır.

Bir model eğitilirken verinin büyük bir kısmı eğitim için kullanılır. Verinin bir kısmı ise test işlemi için ayırılır. Bu iki grup kıyaslanarak eğitimin başarısı değerlendirilir. Olması gereken çıkış değeri ile, tahmin edilen çıkış değeri arasındaki fark kayıp fonksiyonu olarak adlandırılır. Sigmoid, softmax, çok sınıflı destek vektör makinaları gibi fonksiyonlar, sinir ağının ürettiği değerleri normalize etmek için kullanılabilir.

Kayıp fonksiyonu, çeşitli teknikler ile minimize edilmeye çalışılır. Sinir ağlarında geriye doğru yayılım ile ağırlık ve bias değerleri güncellenir. Bu şekilde oluşturulan modelin başarısı arttırılır.

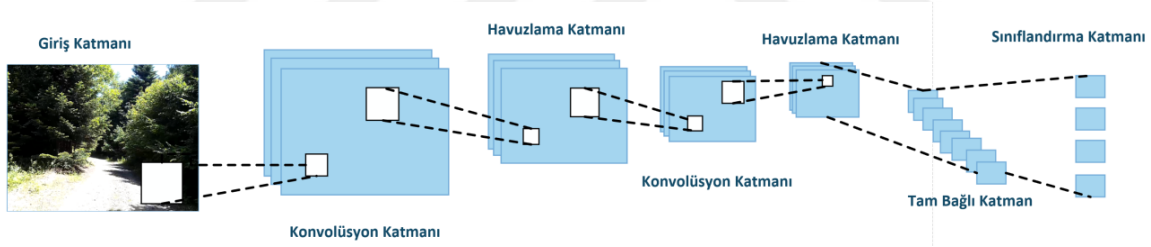
Kayıp fonksiyonu ağırlık değerlerinin sıfıra eşit olması haricinde sıfır değerini almaz. Yani model çok iyi eğitilse bile mutlaka bir hata oranı olacaktır. Bunun sebebi ise fonksiyona genellikle eklenmesi tercih edilen iyileştirme değeridir. Bu değer, model eğitim başarısına olumlu katkısından dolayı kullanılır.

3.2 Konvolüsyonel Sinir Ağları

Yapay sinir ağlarının derinleştirilmesi ile elde edilen konvolüsyonel sinir ağları, konu ile ilgili temel mimari halini almıştır. Konvolüsyonel sinir ağları, Şekil 3.3 üzerinde de görüldüğü üzere, bir kaç farklı katmandan oluşmaktadır. Ardışıl katmanlar eğitilerek sınıfllandırıcılar elde edilir.

Yapay sinir ağlarında bulunan gizli katman sayısının artması ağın derinleşmesine ve derin sinir ağı haline gelmesini sağlamıştır. Ayrıca düğüm seyreltme katmanı ile ezberlemenin önüne geçilmesi de yapay sinir ağlarından ayrıldığı bir diğer noktadır. Derinleşen katmanlarda kenarlar, nesne parçaları ve nesneler sırası ile öğrenilerek ilerlenir.

Konvolüsyonel sinir ağında giriş katmanından alınan veri, katmanlarda ileri doğru iletilerek, öğrenme işlemi gerçekleştirilir. Eğitim sonucu alınan çıktı, olması gereken değer ile karşılaştırılarak, elde edilen farktan hata oranı elde edilir. Bu hata geri yayılım kullanılarak ağırlıkların güncellenmesi için kullanılır. Her yinelenen işlemde hata azaltılarak, optimum değerlere ulaşılmaya çalışılır.



Şekil 3.3 Konvolüsyonel Sinir Ağı Mimarisi

3.2.1 Giriş Katmanı

Sinir ağına verinin girdiği bu katman, giriş katmanı olarak isimlendirilir. Çalışılacak veri görü, ses ya da farklı bir sinyal verisi olabilir. Bu çalışma içerisinde görü verisinin işlenmesi ile ilgilenilmiştir. Giriş katmanına verilecek görüntü çözünürlüğü arttıkça başarım oranı ve ağın başarısı artacak olsada, eğitim süresi ve bellek ihtiyacı ciddi oranda etkilenir. Verinin renkli ya da siyah beyaz olması arasında bile üçte bir oranı kadar matris boyutlarının değişmesine sebep olacağından, donanım kısıtlarına da uygun olan, optimum değerlerin seçilip uygulanması önemlidir.

Eğitilecek modelin yapısına bağlı olarak, imge boyutlarında ön işlem gerçekleştirmek gerekebilir. Ayrıca bazı modeller kanal sayısı için de özelleşmiş olduğundan, kanal sayısı için de azaltma ya da arttırmanın ön işlem olarak uygulanmasına rastlanır. Piksel derinlik değeri de belek ihtiyacını doğrudan etkileyeceği için, donanım niteliğine uygun veri üzerinde değişiklik yapılması gerekebilir.

3.2.2 Konvolüsyon Katmanı

Bu katman temel olarak, seçilecek filtre boyutu ile imge üzerinde konvolüsyon alınmasına dayanır.

Tek boyutlu sinyaller için ayrık konvolüsyon işlemi (3.2)'de görüldüğü şekilde tanımlanır.

$$y[n] = \sum_{k} x[k]h[n-k] \tag{3.2}$$

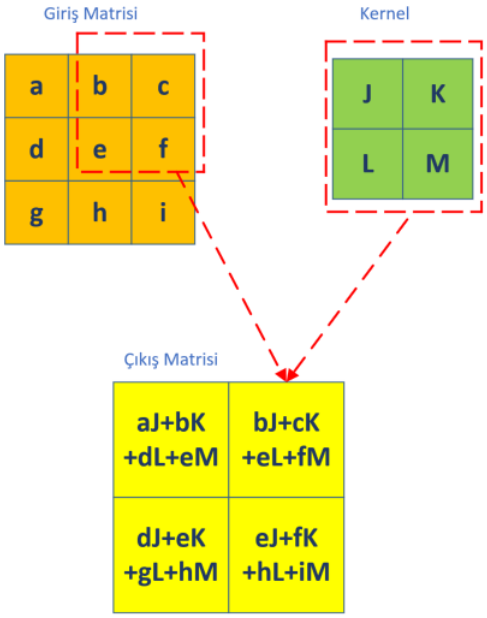
İmge gibi iki boyutlu sinyaller için, iki boyutlu konvolüsyon alınır. (3.3)'de görüldüğü şekilde, x iki boyutlu sinyali üzerine h konvolüsyon kerneli uygulanır. Şekil 3.4 üzerinde örnek görülmektedir.

$$y[m,n] = \sum_{i,j} x[i,j]h[m-i,n-j] \tag{3.3}$$

Gri seviyeli imgeler tek kanal olduğu için iki boyutlu konvolüsyon kullanılır. Ancak renkli imgeler üç kanal için ayrı matrisler şeklinde ifade edilir ve (3.4)'de görüldüğü şekilde üç boyutlu konvolüsyon alınması gereklidir.

$$y[m,n,k] = \sum_{k=0}^{2} \sum_{i} \sum_{j} x[i,j,k]h[m-i,n-j,k] \tag{3.4}$$

Kernel, giriş matrisi üzerinde her seferinde tek adım ilerleyerek dolaştırılabileceği gibi yatayda ve dikeyde farklı adım sayıları ile ilerletilebilir. Bu çıkış matrisinin boyutunu değiştirecektir. (3.5) ve (3.6) üzerinde adım sayısına bağımlı olarak oluşacak matris boyutu eşitliği görülmektedir. W_y ve H_y çıkış matrisi genişliği ve yüksekliğini ifade eder. W_x ve H_x giriş matrisi, W_k ve H_k kernel matrisi boyutlarını temsil eder. S_w ve S_h dikeyde ve



Şekil 3.4 İki Boyutlu Konvolüsyon

yatayda adım sayısını ifade eder. P ise, çıkış matrisi boyutunu düzenlemek için yapılan piksel ekleme işleminde kullanılan değeri ifade eder. Boyutu düzenlemek için yapılan piksel ekleme işleminde, sıfır değeri tercih edilebileceği gibi, bitişiğinde bulunan pikselin değerini kopyalamak da tercih edilen bir yöntemdir.

$$W_y = 1 + \frac{W_x - W_k + 2P}{S_w} \tag{3.5}$$

$$H_y = 1 + \frac{H_x - H_k + 2P}{S_h} \tag{3.6}$$

3.2.3 Düzleştirilmiş Doğrusal Birim Katmanı

Çoğunlukla ReLu (Rectified Linear Units Layer) kısaltması ile ifade edilen, düzleştirilmiş doğrusal birim katmanı, konvolüsyon katmanlarının ardından uygulanır. Aktivasyon katmanı olan bu katmanın temel görevi, negatif değerleri sıfıra eşitlemesidir. Bu katmanın öğrenme hızına olumlu bir etkisi olmasının yanında, ağın üzerinde doğrusal yapıdan çıkarma şeklinde bir etkisi vardır.

3.2.4 Havuzlama Katmanı

Konvolüsyon için giriş boyutunun düzenlendiği katmandır. Boyut indirgeme işlemi gerçekleştirilir. Ara katman olarak, çoğunlukla düzleştirilmiş katmandan sonra uygulanır. Bilgi kaybı tahmin edilenin aksine model üzerinde olumlu etki eder. Boyut indirgemenin faydası hesap yükünü ilerleyen katmanlarda azaltmasıdır. Bu işlemin bir başka sonucu ise, sistemin veri setine fazla bağımlı kalarak ezberlemesini önlemesidir.

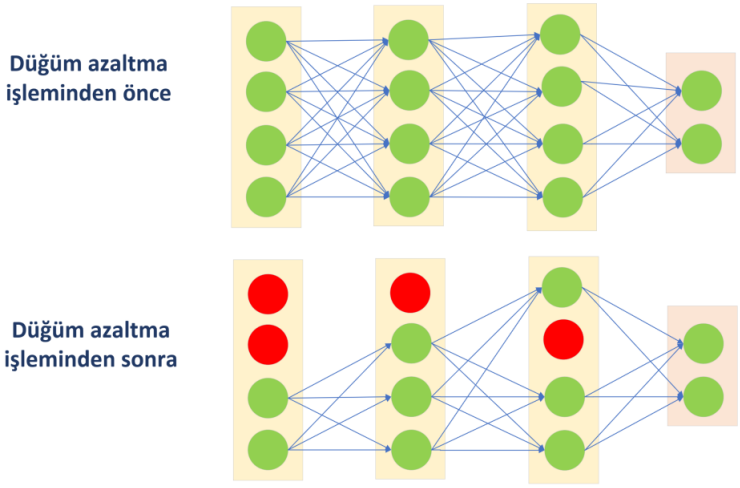
İndirgeme işlemi filtrelerin matris üzerinde belirli adım sayılarında kaydırılması ile gerçekleştirilir. Piksellerin ortalama değerini ya da maksimum değerini alan filtreler sıklıkla tercih edilir. Özellikle maksimum değer kullanımında yüksek başarım görüldüğü için sıklıkla tercih edilir.

3.2.5 Tam Bağlı Katman

Ardışıl birden çok konvolüsyon ve havuzlama katmanının sonrasında, genellikle konvolüsyonel sinir ağları tam bağlı katmanlar ile sürer. Önceki katmanda bulunan matris verisi, vektöre dönüştürülür. Kendinden önce gelen katmanın tüm alanlarına bağlı olmasından dolayı bu adı alır. Konvolüsyon katmanlarından çıkartılan öznitelikler ile asıl ağın oluştuğu katmandır.

3.2.6 Düğüm Seyreltme Katmanı

Şekil 3.5 üzerinde de görüleceği şekilde, bu katmanda ağ üzerinde bazı düğümler kaldırılır. Bunun sonucu olarak, ağın ezberlemesi yani veri setine bağımlı kalması durumu ortadan kaldırılmaya çalışılır.



Şekil 3.5 Düğüm Seyreltme

3.2.7 Sonuç Katmanı

Sonuç katmanının çıkış değeri, sınıf sayısına eşittir. Bu şekilde katmanda sınıflandırma yapılabilir. Normalizasyon için bir çok algoritma kullanılabilir. Çok katmanlı algılayıcı, destek vektör makinesi, k-en yakın komşuluk, softmax gibi algoritmalar bunlara örnektir. Bu algoritmalardan destek vektör makineleri benzerlik değeri üretir. Softmax ise ilgili sınıfa benzerlik olasılıklarını üretir. Sınıflar arası fark daha kolay anlamlandırılabildiği için genellikle sınıflandırma problemleri için softmax tercih edilir.

Modelin verdiği çıkış değerleri normalize edilmemiş değerlerdir. Softmax kullanılarak normalizasyon ile olasılık değerleri elde edilir. Sınıflandırma için olasılık değerlerinden faydalanır. Olasılıksal olarak değeri, diğer sınıflara göre yüksek olan sınıf tercih edilir.

4. MATERYAL VE YÖNTEM

4.1 Geliştirme Ortamı

Bu başlık altında, tez kapsamında kullanılan geliştirme ortamından bahsedilmiştir. Eğitim bilgisayarı, geliştirme kartı ve yazılımların genel özellikleri kısaca tanıtılmıştır.

4.1.1 Eğitim Bilgisayarı

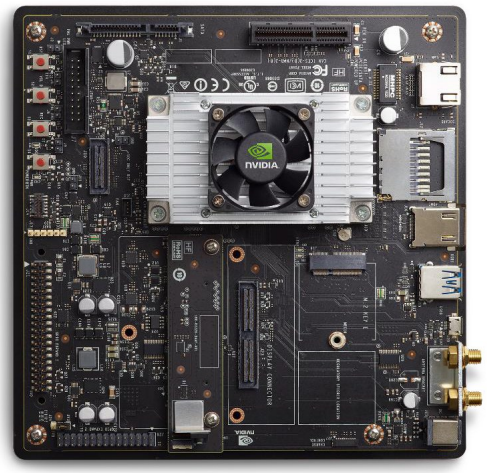
Derin ağ modellerinin geliştirildiği ve veri setlerinin eğitilmesi için kullanılan bilgisayarın işletim sistemi, Ubuntu 16.04.4 LTS Xenial Xerus olarak seçilmiştir. Kullanılan kütüphane ve yapıların GNU/Linux tabanlı geliştirilmiş olması ve Ubuntu için paketlere daha rahat erişilmesi sebebiyle böyle bir tercih yapılmıştır. Bilgisayara ait anakart Gigabyte markasının GA-Z77-DS3H modelidir. Üzerinde Intel Core i7 tipi işlemci birimi bulundurmaktadır.

Grafik kartı olarak, NVIDIA markasının GeForce GTX 1060 modeli kullanılmıştır. Özellikle DIGITS ile yapılan eğitimlerde bellek boyutu önemli olduğu için, bütçe dahilinde 6 GB çerçeve arabelleğe sahip bu model tercih edilmiştir. Pascal mimarisine sahip bu grafik birimi üzerinde 1280 adet CUDA çekirdeği bulundurmaktadır.

4.1.2 Jetson TX2 Geliştirme Kartı

Grafik işlemci birimlerinin gömülü sistemlerde de kullanılmaya başlanması ile, robot ve drone uygulamalarında grafik işlemcili kartlar kullanılmaya başlandı. NVIDIA firmasının yapay zeka uygulamaları için oluşturduğu Jetson serisinde, en gelişmiş modül olan TX2 bu uygulamada kullanılmak amacı ile tercih edilmiştir. TX2 modülü geliştirme kartı ile birlikte kullanılmıştır. Bu şekilde hem işlemleri monitörize etmek hem de dış birimleri karta bağlamak, bu birim yardımı ile kolaylaşmıştır.

NVIDIA Pascal mimarisine sahip olan bu kart, 256 CUDA çekirdeği bulundurur. Üzerinde bulundurduğu dahili kameranın dışında, Ethernet ve USB portları bulundurmaktadır. HDMI çıkışa sahip kart, ayrıca 802.11ac Wi-Fi ve Bluetooth bağlantısı da gerçekleştirebilmektedir. Üzerinde GNU/Linux tabanlı bir geliştirme ortamı sunan kart, bir çok yapay zeka yapısını desteklemektedir. Linux for Tegra kart destek paketi ile çalışmaktadır. Şekil 4.1 üzerinde geliştirme kartı görülmektedir.



Şekil 4.1 TX2 Geliştirme Kartı (NVIDIA, 2016)

4.1.3 Caffe

Caffe, modüler bir derin öğrenme yapısıdır. Berkeley AI Research ekibi tarafından geliştirilmektedir. Açık kaynaklı olduğu için, geliştirme tarafında konu ile ilgili topluluktan da destek görmektedir. Birçok yazılım dili ve ortamı ile kullanılmaktadır. Yapay öğrenme konusunda kullanımı oldukça yaygın ve popüler bir yapıdır. Akademik araştırmalar ile kullanımına sıkça rastlanmak ile birlikte, endüstri alanında da kullanımı oldukça yaygın görülmektedir.

Bu tez kapsamında DIGITS ile entegrasyonu sebebiyle model eğitimleri için kullanılmıştır. Jetson TX2 üzerinde yapılan uygulamada da, eğitim sonucu oluşturulan Caffe model dosyaları kullanılmıştır. DIGITS'den dışarı aktarılan caffemodel uzantılı dosya, kart üzerinde python dili ile kullanılarak sınıflandırma gerçek zamanlı çalıştırılmıştır. Bu işlemin gerçekleştirilebilmesi için kart üzerinde de Caffe'nin kurulu olması gerekmektedir.

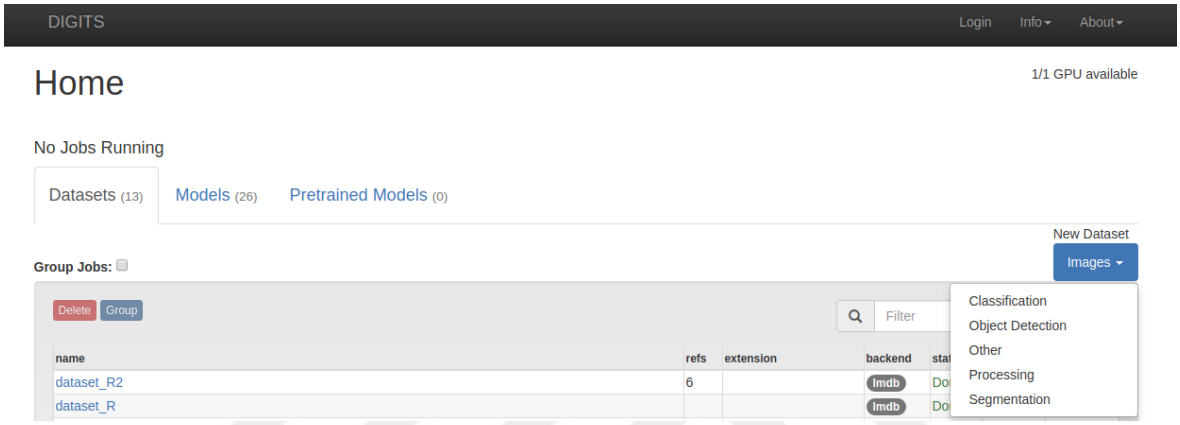
Şekil 4.2 üzerinde Caffe'nin, Google'ın geliştirdiği bir yapı olan protocol buffers ile kullanımı görülmektedir. Verinin istenilen şekilde ifade edilmesi için kullanılan bu yapı ile model, okunurluğu yüksek bir şekilde tanımlanabilmektedir. Şekil 4.2 üzerinde örnek üzerinde AlexNet modelinin ilk katmanlarının tanımlanması görülmektedir.

```
# AlexNet
name: "AlexNet"
layer {
  name: "train-data"
  type: "Data"
  top: "data"
  top: "label"
  transform_param {
    mirror: true
    crop_size: 227
  }
  data_param {
    batch_size: 128
  }
  include { stage: "train" }
}
layer {
  name: "val-data"
  type: "Data"
  top: "data"
  top: "label"
  transform_param {
    crop_size: 227
  }
  data_param {
    batch_size: 32
  }
  include { stage: "val" }
}
layer {
  name: "conv1"
  type: "Convolution"
  bottom: "data"
  top: "conv1"
  param {
    lr_mult: 1
    decay_mult: 1
  }
  param {
    lr_mult: 2
    decay_mult: 0
  }
  convolution_param {
    num_output: 96
    kernel_size: 11
    stride: 4
    weight_filler {
      type: "gaussian"
      std: 0.01
    }
```

Şekil 4.2 Protocol Buffer yapısı ile AlexNet model katmanları ifadesi

4.1.4 DIGITS

NVIDIA firmasına ait bir ürün olan DIGITS (Deep Learning GPU Training System) derin öğrenme ağları ile sınıflandırma, segmentasyon ve nesne tanıma çalışmalarını gerçekleştirmeyi sağlar. Derin sinir ağlarını tasarlamayı, eğitmeyi ve görselleştirmeyi sağlar. NVCaffe, Torch ve TensorFLow yapılarını doğrudan kullanmaya olanak verir. AlexNet, GoogLeNet, LeNet ve UNET gibi önden eğitilmiş modelleri de sistem üzerinde doğrudan kullanmak mümkündür. Grafik web arayüzü üzerinden bu yapılar doğrudan kullanılabilir.

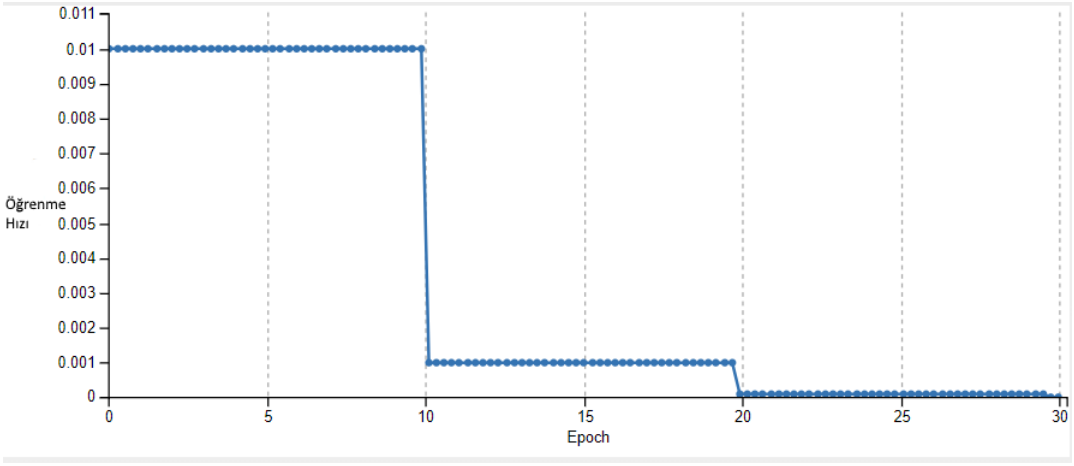


Şekil 4.3 DIGITS ana ekranı

İlk adım olarak amaca uygun veri seti oluşturulur. Sınıflandırma, nesne tanıma veya bölütleme gibi amaç seçildikten sonra, istenilen sınıflara uygun veri sisteme uygun tanıtıllmasının ardından, parametrelere uygun veri seti oluşturulur. Çalışmaya uygun olarak oluşturulan veri seti ile bir model tasarlanır. Tamamen yeni bir model kullanılabileceği gibi önceden eğitilmiş modeller de tercih edilebilir. Ayrıca eğitim sonrasında limitli de olsa bir test imkanı bulunmaktadır. Şekil 4.3 üzerinde Digits ana ekranı görülmektedir.

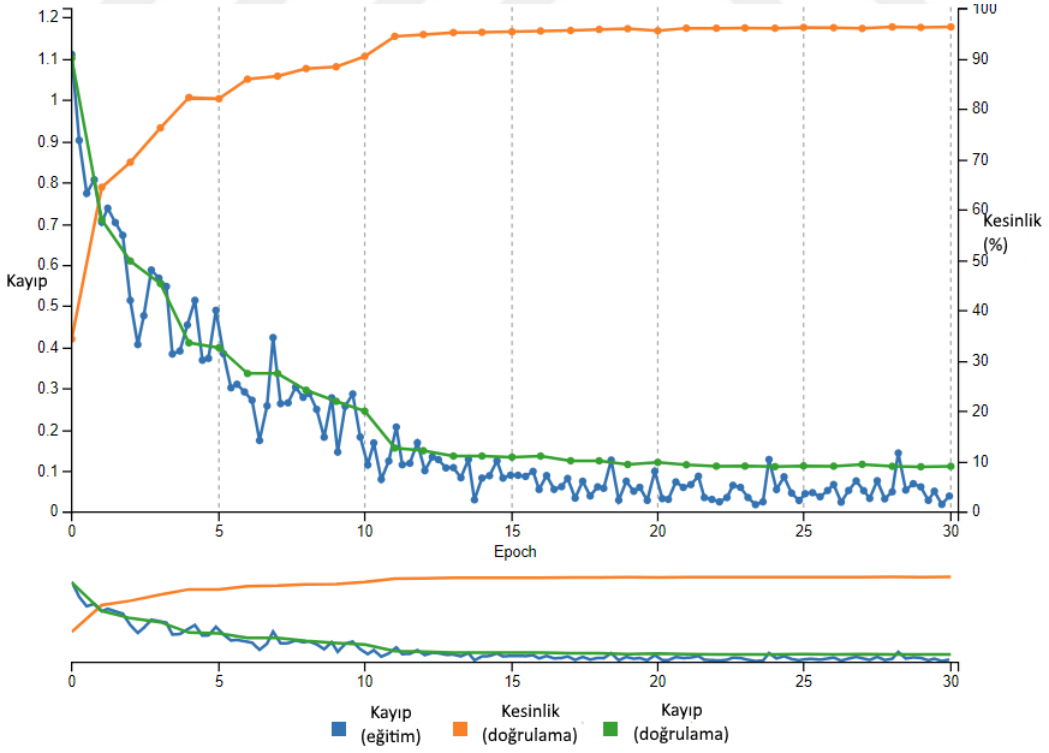
DIGITS gerçekleştirilen eğitim faaliyeti sırasında öğrenme hızı, kayıp fonksiyonu gibi bilgileri anlık olarak arayüzü üzerinden sunması ile de fayda sağlar. Eğitim için parametrik değişklik kararı bu şekilde daha hızlı alınabilir.

Epochlar olası girdiler için ağırlıkların güncellenme sayısıdır. Öğrenme hızı, hedefe varmak için gerekli adım büyüklüğü olarak düşünülebilir. Şekil 4.4 üzerinde de görüldüğü şekilde, bazı noktalarda kesin düşüşler gerçekleştirir. Öğrenme maliyeti açısından, yüksek fayda sağlanmayan noktadan sonrası olan epochlar sonuç için büyük farklılık yaratmazlar. Bu örnek üzerinde görülen model için bu durumda yirmi epoch eğitim için yeterlidir.



Şekil 4.4 Epoch - öğrenme hızı ilişkisi

Kayıp fonsiyonunun optimize edilerek, model çıktısı ve gerçek değerin yakınlaştırılması ile öğrenme gerçekleştirilir. DIGITS üzerinde Şekil 4.5'de de görülen şekilde grafik incelenebilir. Hem eğitim hem de eğitim esnasında doğrulama için kullanılan verilerin kayıp fonksiyonları, epoch ilişkili olarak görülmektedir.

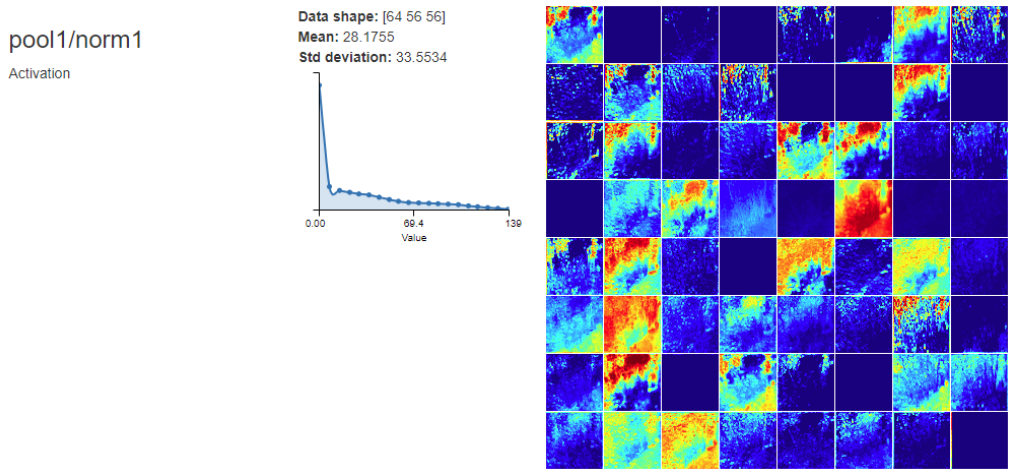


Şekil 4.5 Kayıp fonksiyonu - öğrenme hızı ilişkisi

Digits aynı zamanda imgelerin test edilmesi içinde kullanılır. İmgelerin bulunduğu klasörün, imge listesi ile birlikte işaret edilmesi ile birlikte, eğitilen modeller istenilen görseller ile denenebilmektedir. Ayrıca tek bir imge için test uygulanabilir. Tek imge için yapılan bu testin çıktısı olarak, modelin ara adımlarında oluşan çıkan sonuçlar ile ilgili fikir edinilebilmektedir. Şekil 4.6 üzerinde görülen imgenin, GoogLeNet modeli ile denenmesi sonucu Şekil 4.7 üzerinde ilk havuzlama katmanından sonra oluşan verinin görsel ifadesi görülebilmektedir.



Şekil 4.6 Test imgesi



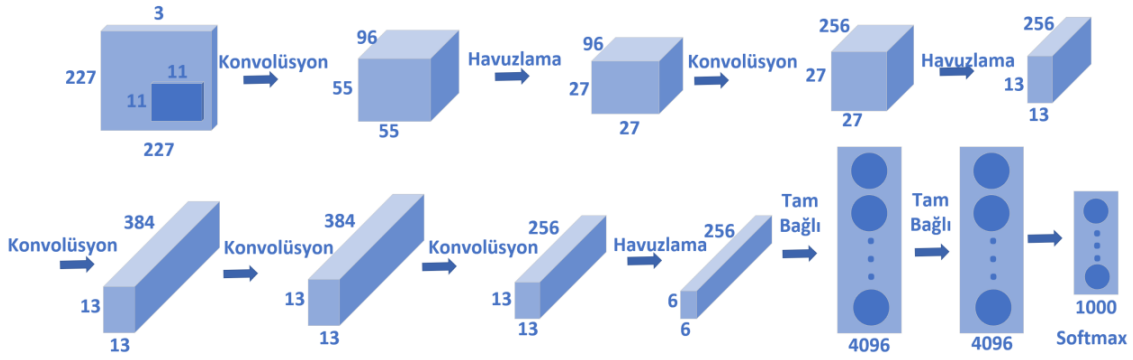
Şekil 4.7 Digits ara katman çıktısı

4.2 Derin Öğrenme Modelleri

Tez kapsamında üç adet derin öğrenme modeli sınıflandırma amacı ile kullanılmıştır. Bu modeller geçmiş yıllarda görsel tanıma ile önemli bir kıyas platformu olan ImageNet yarışmasını kazanmış modeller arasından seçilmişlerdir. Ayrıca yapılarında getirdikleri farklılıklardan dolayı derin öğrenme için temel algoritmalar olarak kabul edilirler. AlexNet (Krizhevsky vd., 2012), GoogLeNet (Szegedy vd., 2014) ve ResNet (He vd., 2015) modelleri tez kapsamında kulllanılmıştır. Farklı modellerin başarı oranlarının ve tepkilerinin ölçülmesi ile geliştirilecek sisteme uygunlukları test edilmiştir.

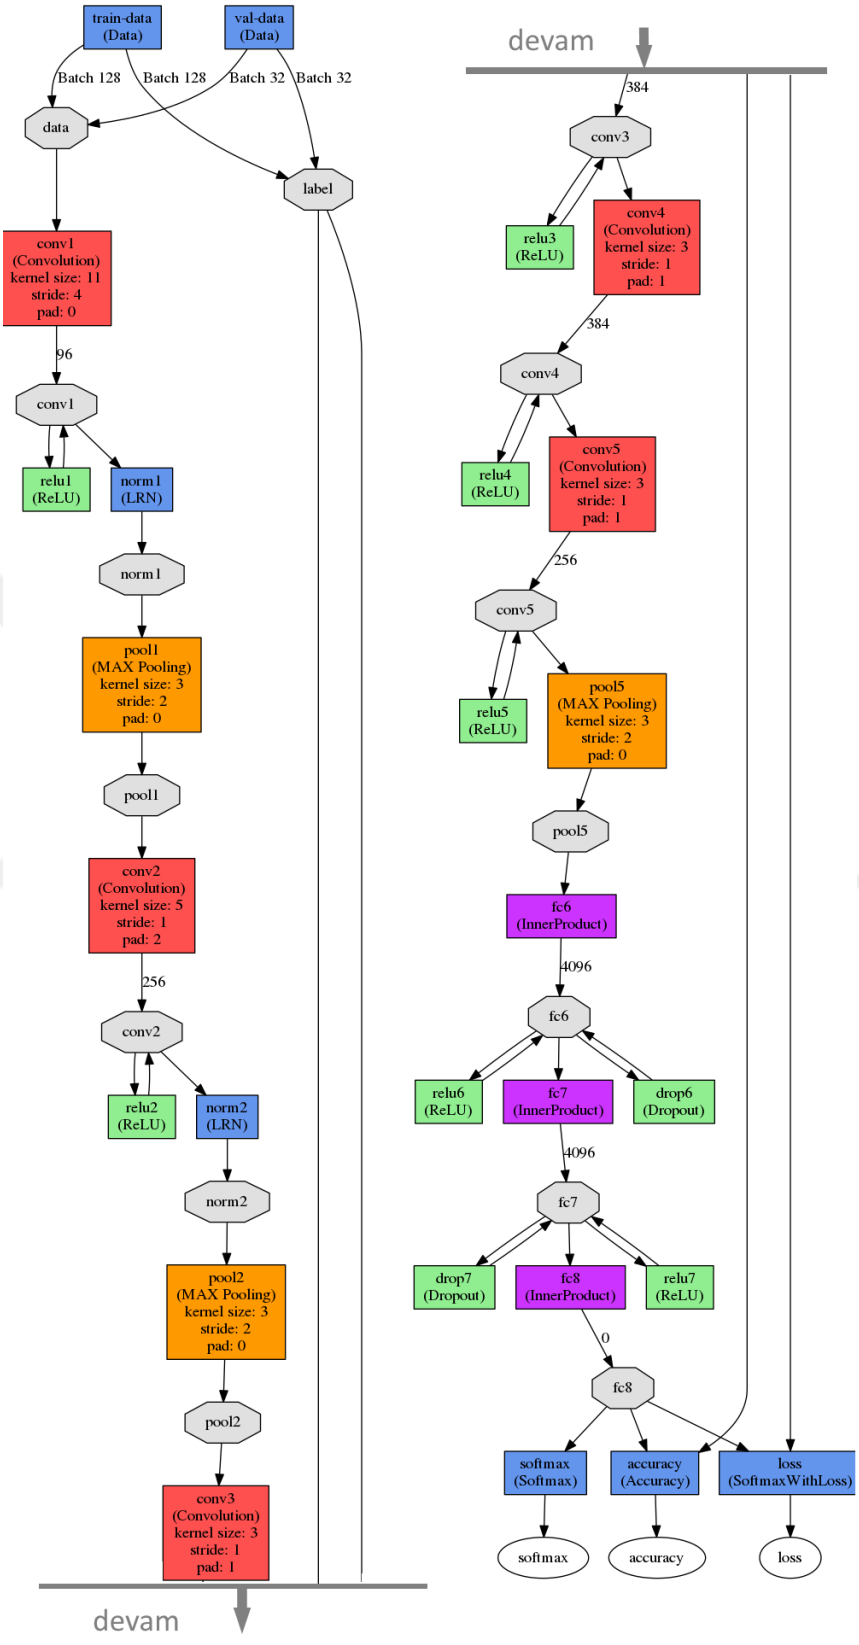
4.2.1 AlexNet

AlexNet modeli ImageNet yarışmasına katıldığı sene Top-5 hata oranını %15.3 seviyesine çekmiştir. Bir sonraki iyi metodun hata oranının %26.2 olduğu gözönüne alındığında, yayınlandığı sene yarattığı fark açıkça görülmektedir. Top-5 seviyesi kesinlik, tahmin edilen ilk beş etiketten birinin doğru olması anlamına gelmektedir. Yayının ilk yazarı Alex Krizhevsky'ye ithafen model, AlexNet olarak anılmaktadır. Model 256x256 piksel boyutunda giriş imgelerini kabul eder. Kullanılacak imge bu boyutta değil ise, bu boyuta getirilir. Modelde renkli imge kullanılır. İmge içerisinden rastgele 227x227 boyutlu bölgeler alınır. Beş adet konvolüsyonel katman ve üç adet tam bağlı katman kullanılır. Metod bin adet sınıf çıktısı üretir.



Şekil 4.8 AlexNet katmanları

Şekil 4.8 üzerinde AlexNet katmanları, Şekil 4.9 üzerinde ise tezde kullanılan modelin boyutları ile birlikte adımları görülebilir.



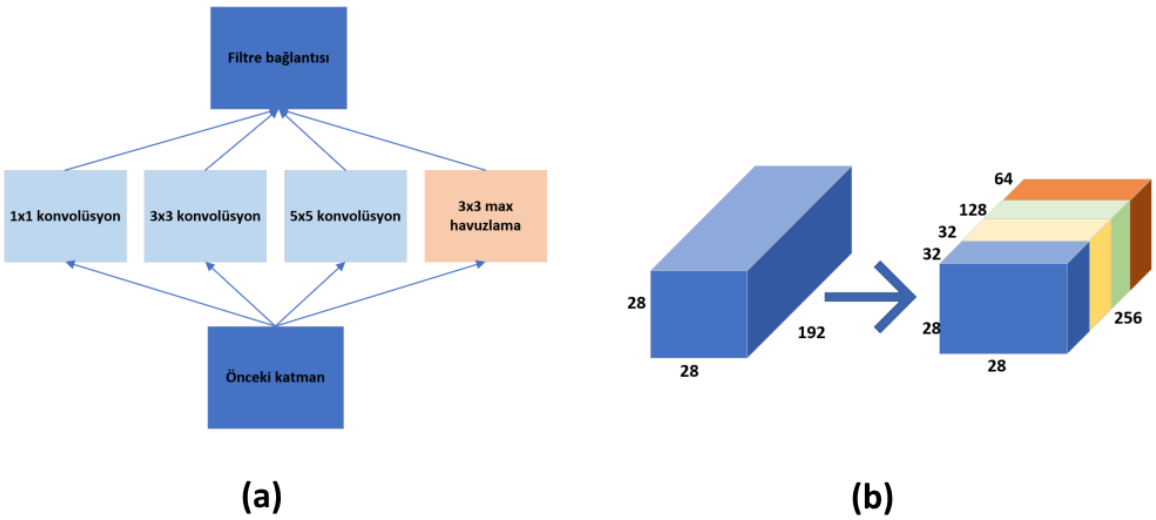
Şekil 4.9 AlexNet modeli

4.2.2 GoogLenet

GoogLeNet (Szegedy vd., 2014), 2014 yılında ImageNet yarışmasını kazanan modeldir. Hata oranını %5.7 gibi bir değere indirmeyi başarmışlardır. Bellek kullanımı açısından öne çıkan bir modeldir. Katmanları çoğaltmak yerine paralel ve bağlı modüller oluşturmuşlardır. Bu yapı çalışma hızına da olumlu katkı etmiştir.

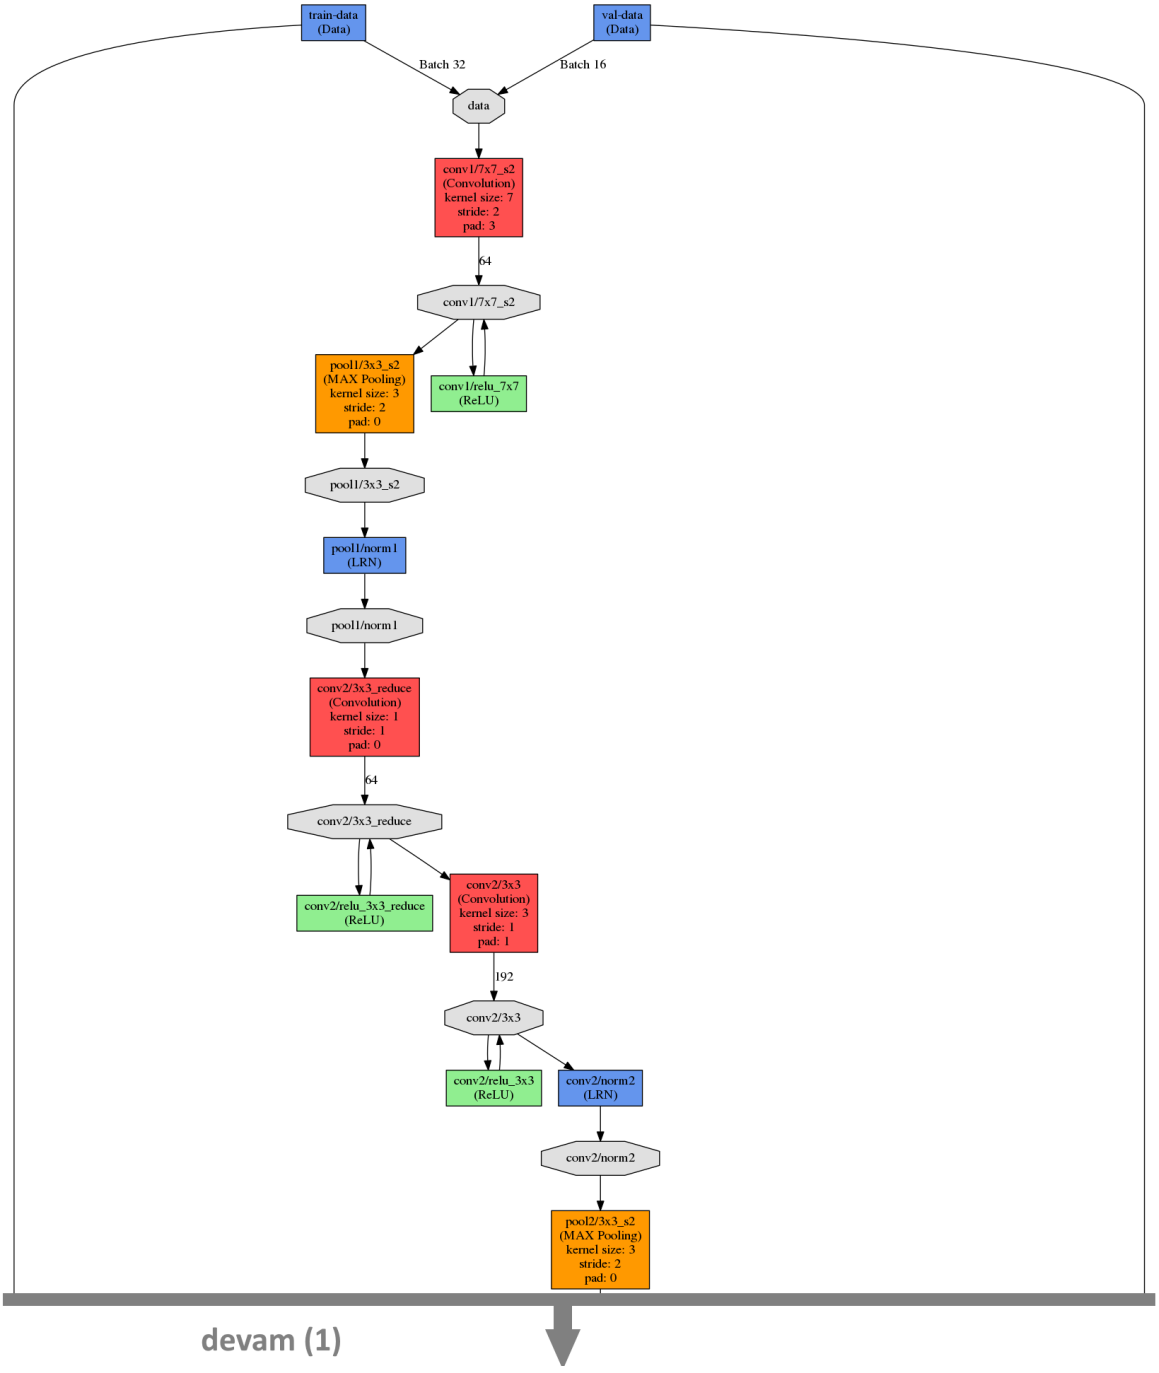
Şekil 4.10 (a) üzerinde inception modülü görülmektedir. Yapının adı, bir sinema filminden ilham alınarak konulmuştur. Modüller farklı boyutlu konvolüsyon ve havuzlama işlemlerini gerçekleştirir. Şekil 4.10 (a) üzerinde üç konvolüsyon ve bir adet havuzlama işlemi ile elde edilen matris görülmektedir. Inception modülü, işlem yükü optimizasyonu ile öne çıkan bir yaklaşımdır.

Parametre sayısı ve boyut artışını önlemek için kullanılan 1x1 konvolüsyonel katmanlar, boyutu küçültme işlevi gerçekleştirler. Şekil 4.10 (a) üzerinde görülen kernel boyutlarına bağlı olarak, daha ufak çıktılar oluştuğu, Şekil 4.10 (b) üzerinde görülebilir. İşlem sayısını da ciddi oranda düşüren bir yaklaşımdır. Model çıkışında tam bağlı katmanlar yerine ortalama havuzlama katmanları kullanılır. Bu da işlem maliyeti bakımından bir avantaja dönüşür. AlexNet ile kıyaslandığında, onun yarısından daha az sayıda parametre kullanmaktadır.

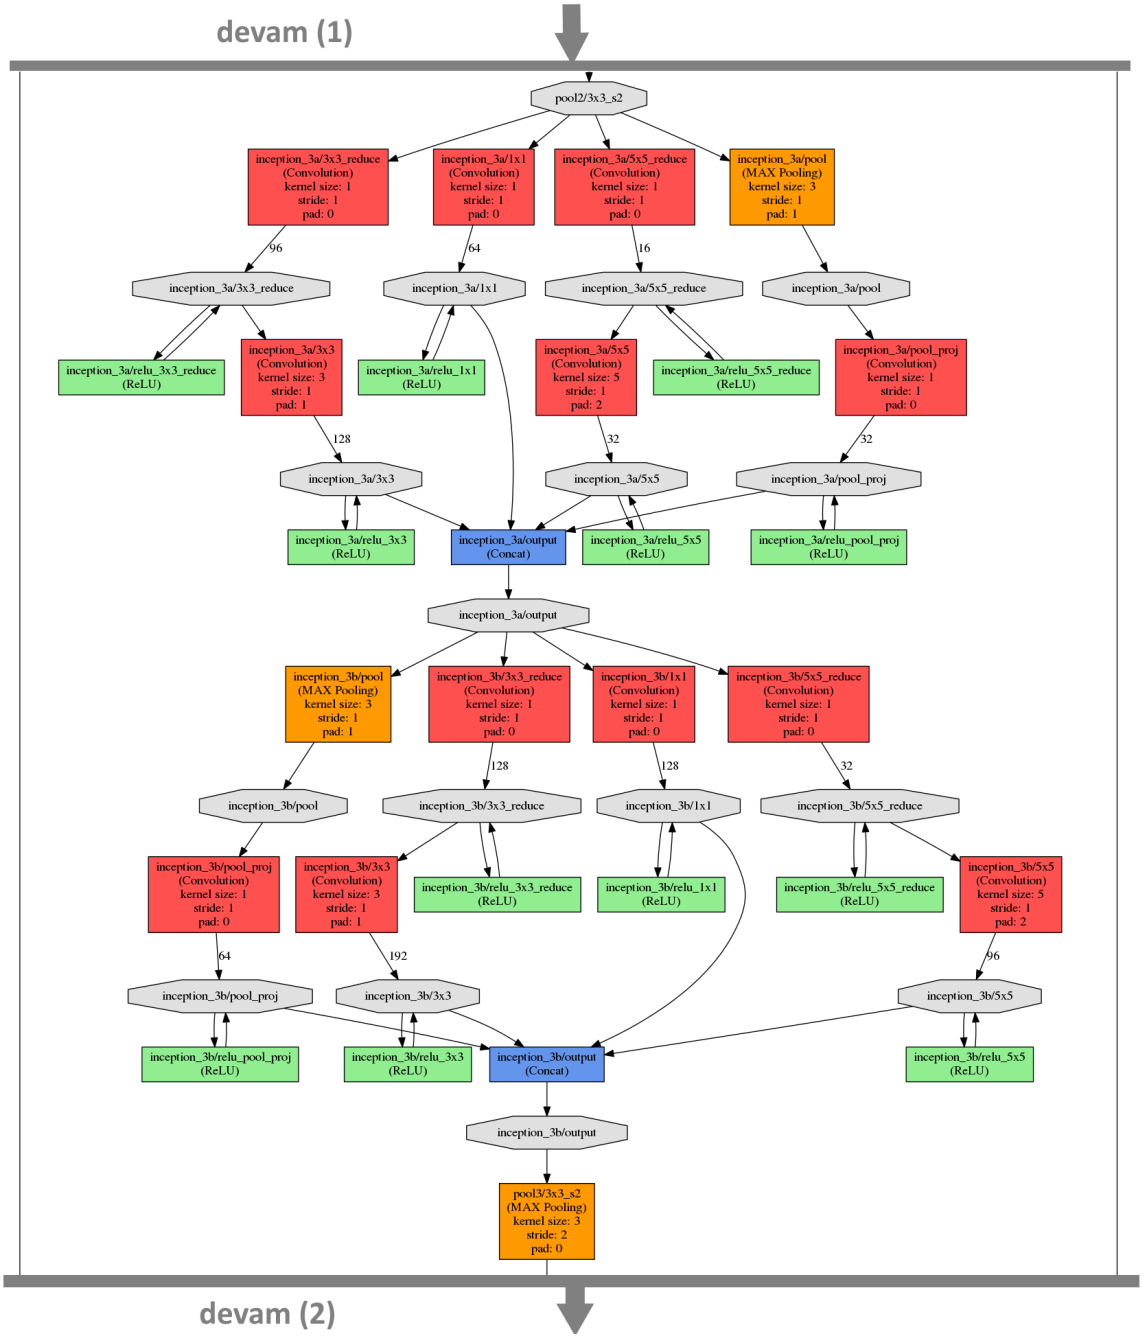


Şekil 4.10 Inception modülü

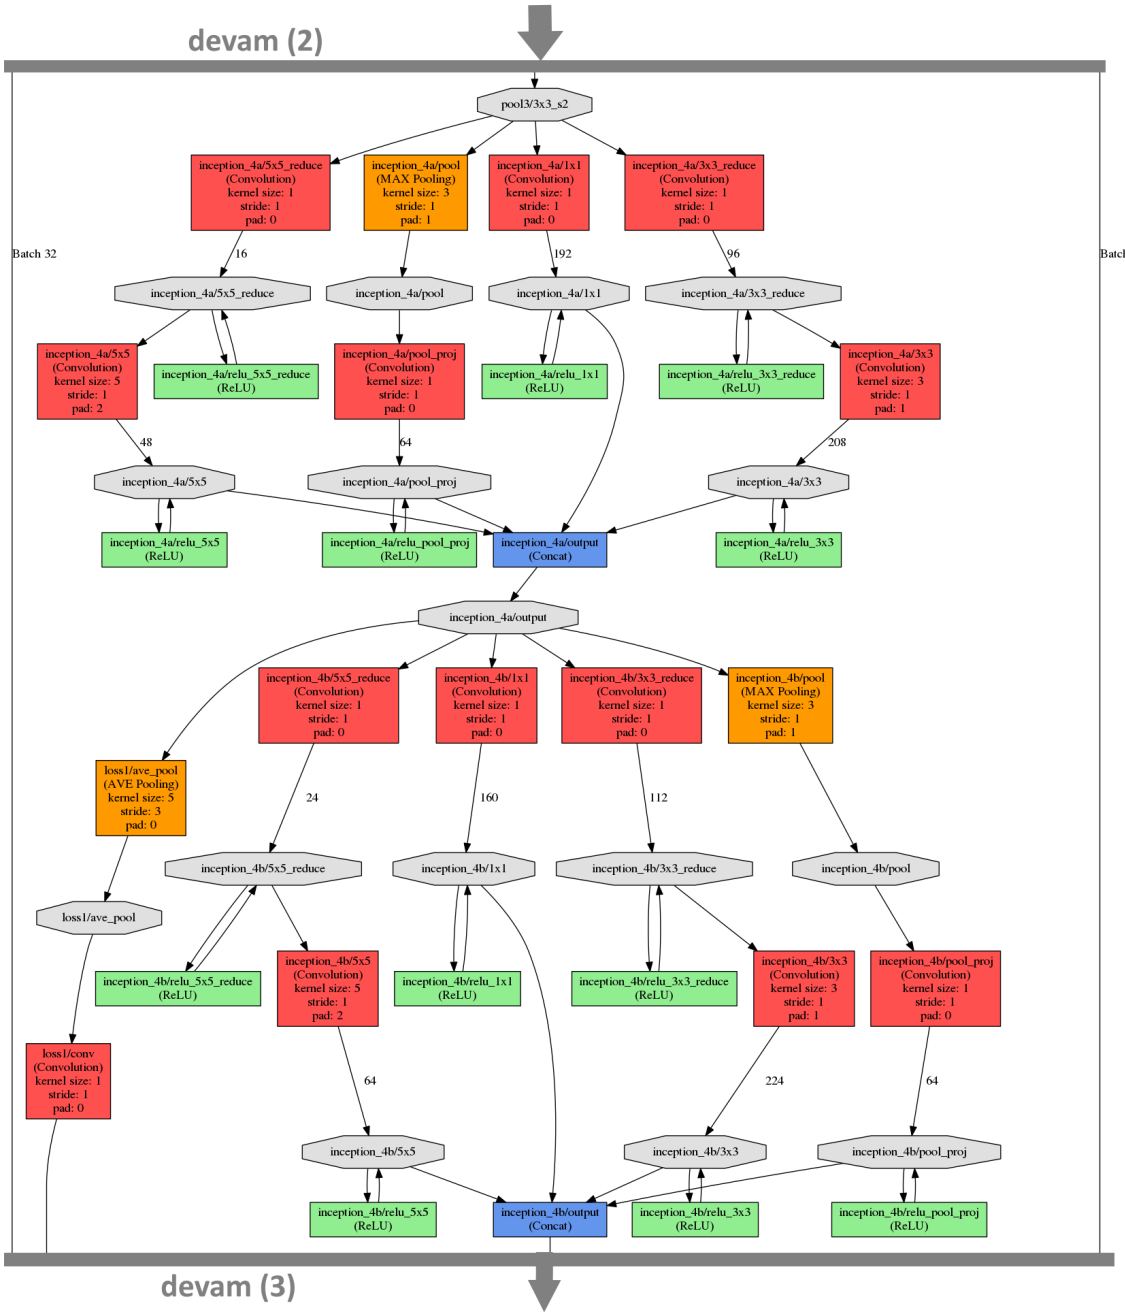
Şekil 4.11, Şekil 4.12, Şekil 4.13, Şekil 4.14, Şekil 4.15 ve Şekil 4.16 üzerinde tezde kullanılan modelin boyutları ile birlikte adımları görülebilir.



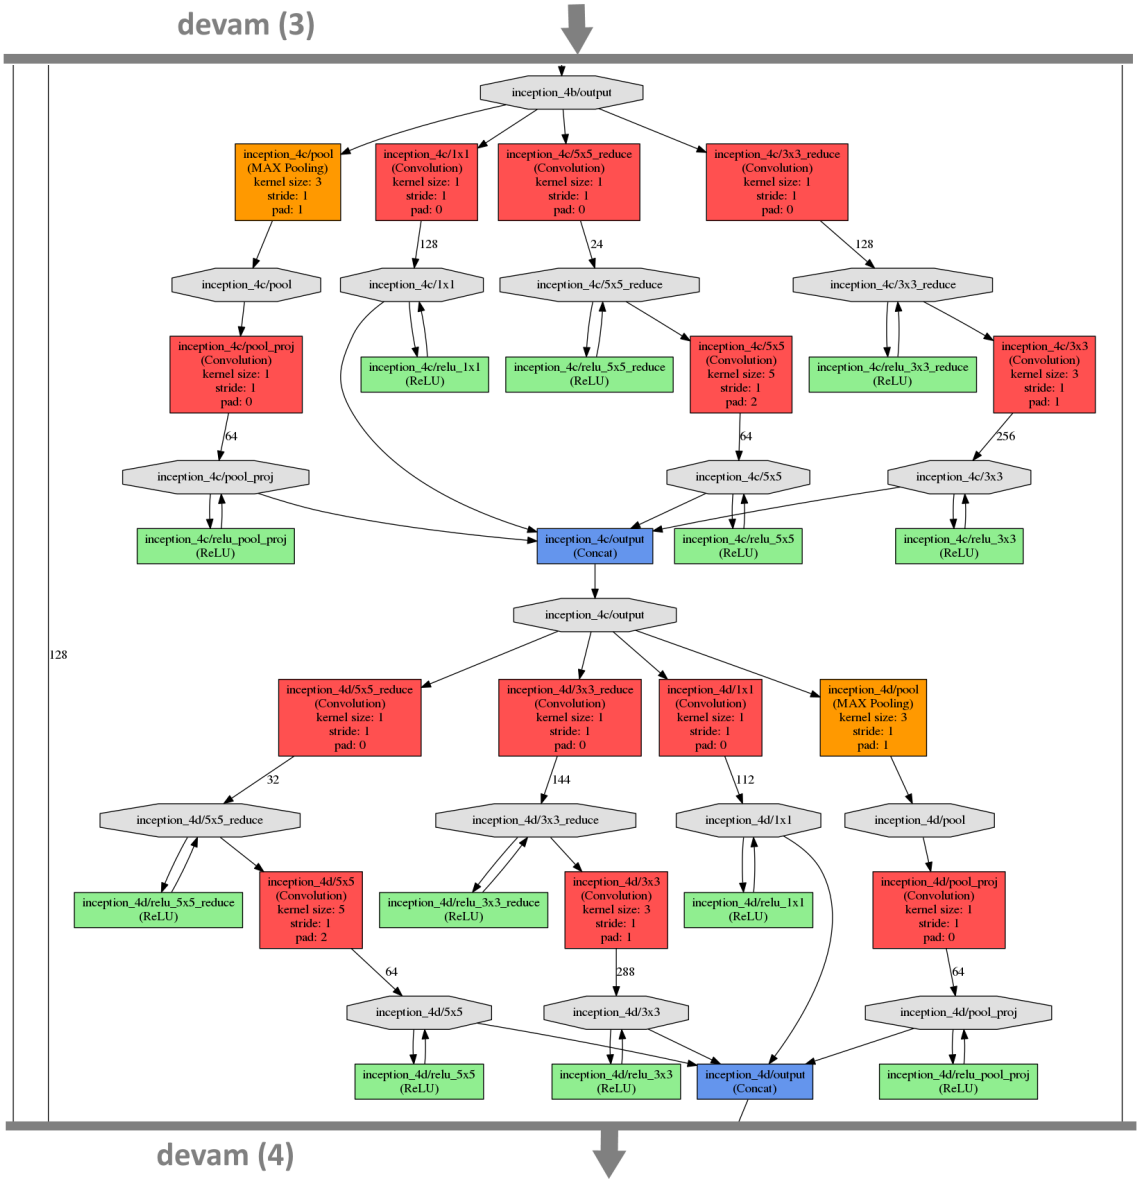
Şekil 4.11 GoogLeNet modeli (1)



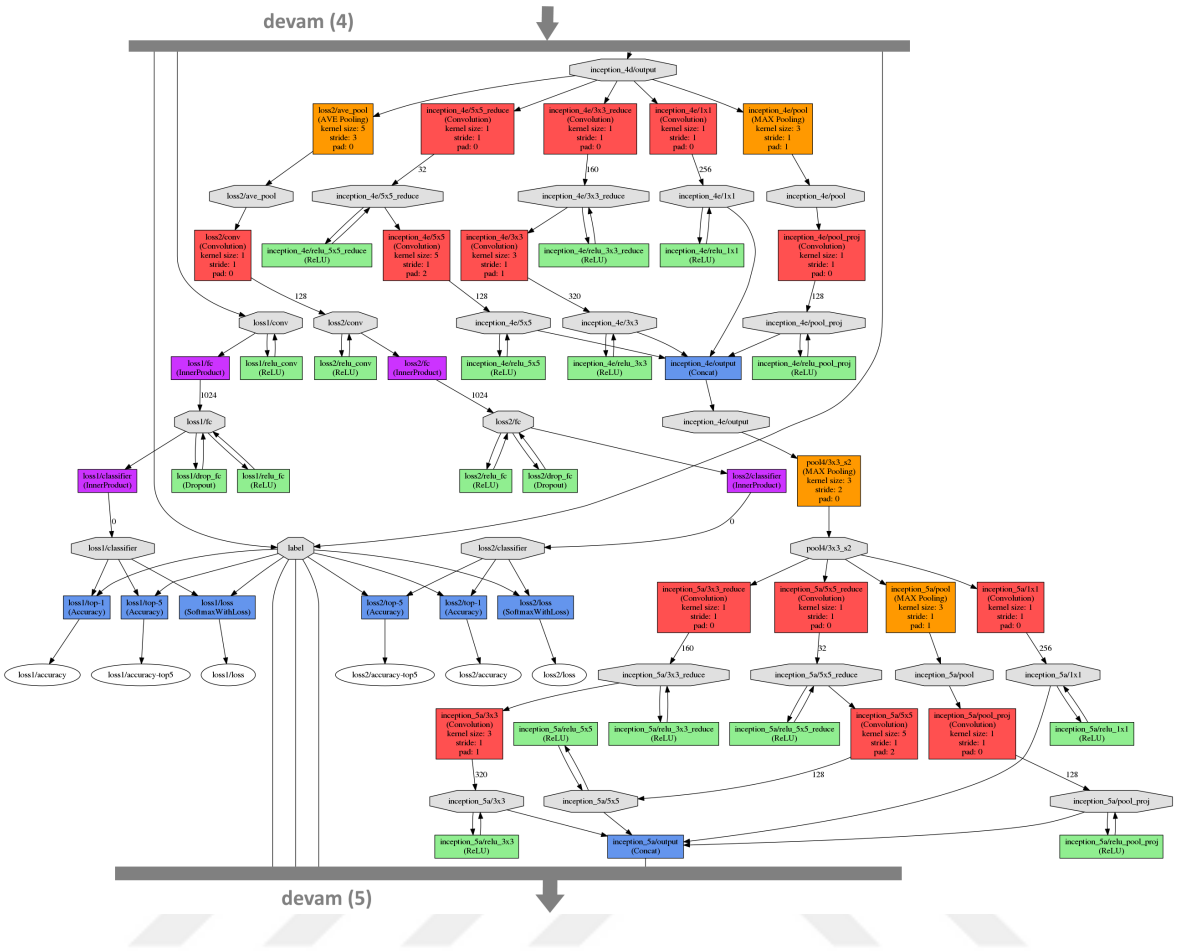
Şekil 4.12 GoogLeNet modeli (2)



Şekil 4.13 GoogLeNet modeli (3)



Şekil 4.14 GoogLeNet modeli (4)



Şekil 4.15 GoogLeNet modeli (5)



Şekil 4.16 GoogLeNet modeli (6)

5. BULGULAR VE TARTIŞMA

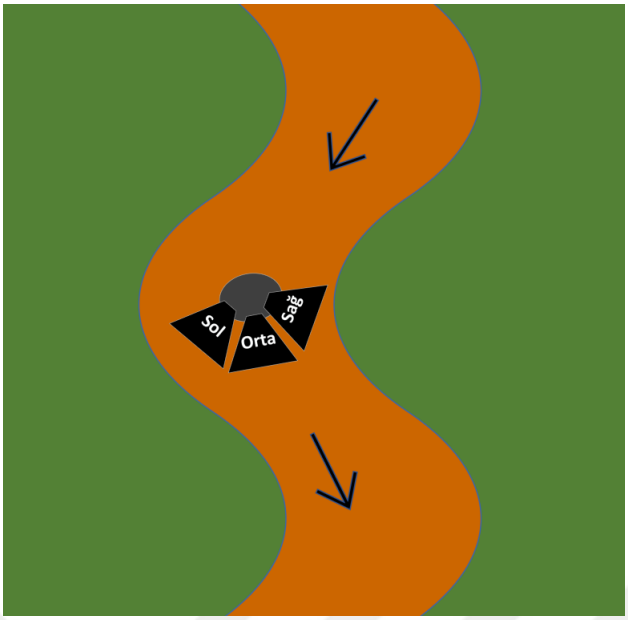
Orman gibi hareket alanının zorlu olduğu bölgelerde, drone ya da mobil robotların gidebileceği patikalarda yön kestirimi yapan modeller araştırılmıştır. Konu ile ilgili çalışmalar literatür bölümünde özetlenmiştir. Çalışmalarda genel olarak, bu tez çalışmasında da kullanılan temel mimariler özelleştirilerek, farklı sensör tiplerinin de desteği ile kullanılmıştır. Bu tez çalışmasında ise sadece görü verisi ile yön önerisi desteği sağlamak hedeflenmiştir.

Kullanılan modeller, patika yollardan toplanan veriler ile özel olarak eğitilmiştir. Kullanılan veri setleri bu alanlara uygun olarak seçilmiştir. Eğitim için Giusti vd.nin çalışmasında (Giusti vd., 2016) bahsedilen veri seti kullanılmıştır. On dört ayrı bölümden oluşan bu setten, birden dokuza kadar olan kısım eğitim amacı ile kullanılmıştır. On, on bir ve on ikinci kısımlar test amacı ile kullanılmıştır. Bu veri seti farklı türde kamera ve bölgelerden elde edilen görüntüleri içermektedir. Bunun yanı sıra ormanlık alandan eğitim ve test amaçlı veriler toplanmıştır. Şekil 5.3 ve Şekil 5.2 üzerinde veri toplanan bölgeler görülebilir.

AlexNet ve GoogLeNet modelleri, Giusti vd.nin (Giusti vd., 2016) veri setinin eğitimde kullanılmayan alt bölümleri ve yine ormanlık alandan tez çalışması için toplanan görüntüler ile test edilmiştir. Test sonuçları bu bölümün devamında aktarılmaktadır.

Giusti vd., 2016 Şekil 5.1 üzerinde de temsilen görülen, aynı düzlemde tutulan üç kamera ile ortam görüntüsü topladıklarını belirtmişlerdir. Sağ, sol ve düz olarak üç bakış açısını temsil eden görüntüler doğrudan etiketlenebildiği için önemli bir fark yaratmaktadır.

Bu çalışmadan ilham alınarak, bu tez çalışmasında da bir monopod üzerine takılmış kameradan sağ, sol ve orta yönlü görüntüler toplanmıştır. Bu görüntülerin bir bölümü test için kullanılırken, bir kısmı ise eğitim verisi olarak değerlendirilmiştir. Toplanan görüntülerin 62861 tanesi eğitim, 7395 adedi ise eğitim sırasında doğrulama maksadı ile kullanılmıştır. Test için bağımsızlığı yaratabilmek adına farklı bir alandan alınan görüntüler kullanılmıştır.

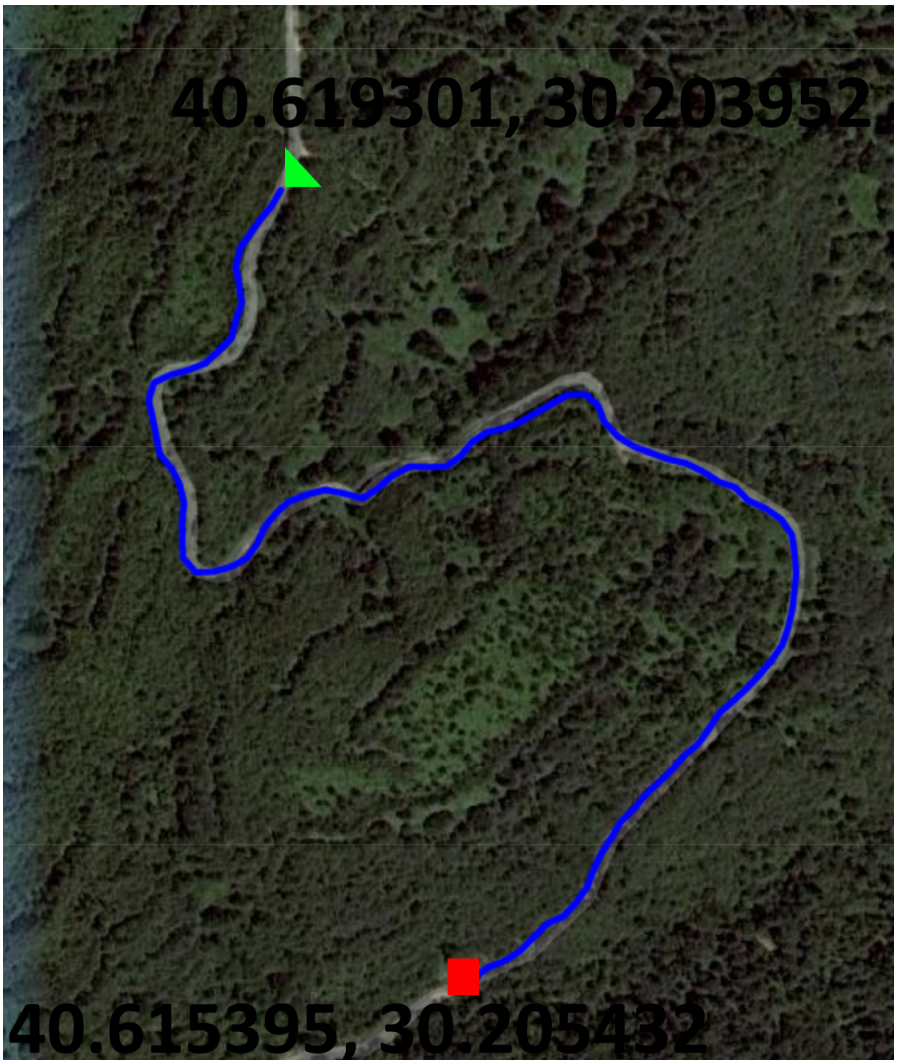


Şekil 5.1 Aynı yönde sağ, sol ve düz olacak şekilde üç farklı bakış açısı için veri toplanması

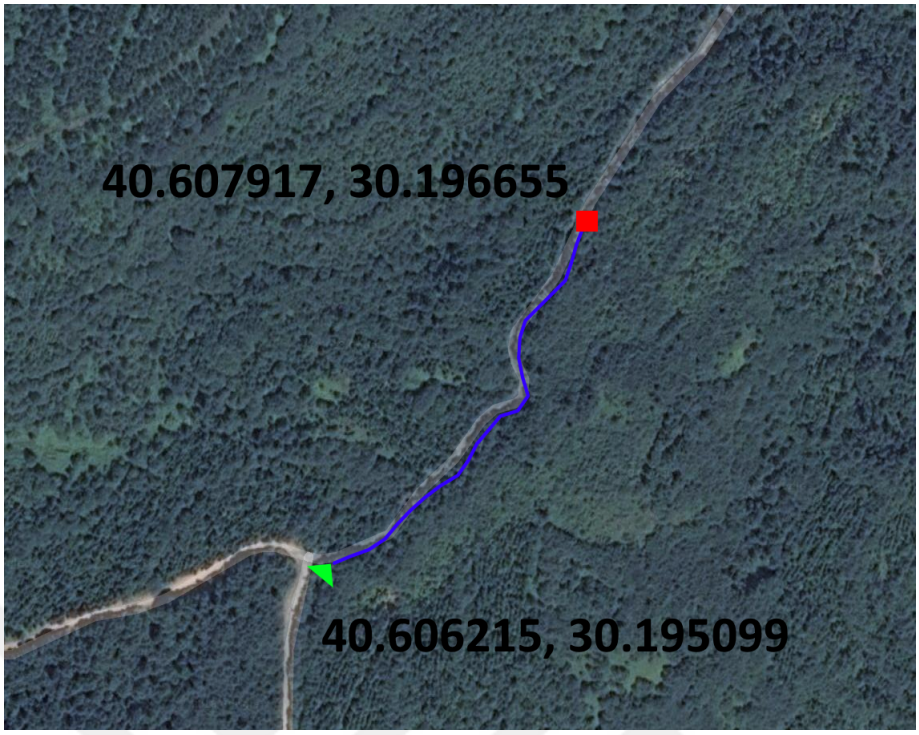
Şekil 5.2 üzerinde görülen bölgede bir kilometre bir patika alan içerinde eğitim amaçlı görüntüler toplanmıştır. Giusti vd.nin (Giusti vd., 2016) veri setine benzer mantıkla toplanan veriler, farklı olarak tek bir kameradan her yön için yeniden kayıt alınarak toplanmıştır. Normal bir yürüyüş hızında ve öğle saati toplanan veriler yaklaşık bir metre altmış beş santimetre yüksekliğinden alınmıştır.

Mevsim itibariyle bahsi geçen çalışmadan farklı olarak daha yeşil bir bölgede çekim yapılmıştır. Bu sebeple eğitim sonucu oluşan model daha farklı bölgeler için de kullanılır hale gelmiştir.

Bu bölgelerin dışında, veri setine dahil edilmeden bir araç kaputuna bağlanan kamera ile yavaş hızla ilerlenip görüntü toplanmıştır. Bu görüntüler araç üzerinde toplanması sebebi ile sadece orta yönlüdür. 5858 adet görüntü iki model ile de test edilmiştir. AlexNet için %96.4, GoogLeNet için ise %90.1 başarım elde edilmiştir.



Şekil 5.2 Veri setinin toplantığı bölge



Şekil 5.3 Test verisinin toplandığı bölge

Veri setinin toplandığı bölge orman alanı içerisinde bir patikadır. Başlangıç noktası koordinat bilgisi 40.619301, 30.203952 şeklindedir. Bitiş koordinatı ise 40.615395, 30.205432 noktasıdır. Bir kilometrelik kıvrımlı olarak ilerleyen patikadan öğle saatlerinde, açık ve güneşli bir havada görüntüler kaydedilmiştir. Test verisi, eğitim verisinin toplandığı bölgede iki yüz elli metrelik farklı bir patikadır. Başlangıç koordinat noktası 40.606215, 30.195099, bitiş koordinatı ise 40.615395, 30.205432 noktasıdır. Test görüntüleri de açık ve güneşli havada kaydedilmiştir..

Şekil 5.4 üzerinde verinin toplandığı alandan sağ, orta ve sol yönlü görüntülere örnekler görülebilir. Hem test hem de eğitim verileri sağ, sol ve orta yönlü olmak üzere aynı rota üzerinde üç yürüyüş ile toplanmıştır. Görüntüler ortalama olarak 165 cm yükseklikten toplanmıştır. Bir monopod üzerinde SJCAM SJ4000 modeli bir aksiyon kamerası kullanılmıştır. 1920x1080 piksel çözünürlük ile saniyede otuz kare olarak kayıt alınmıştır. Ortalama bir yürüyüş hızı ile kayıt toplanmıştır.

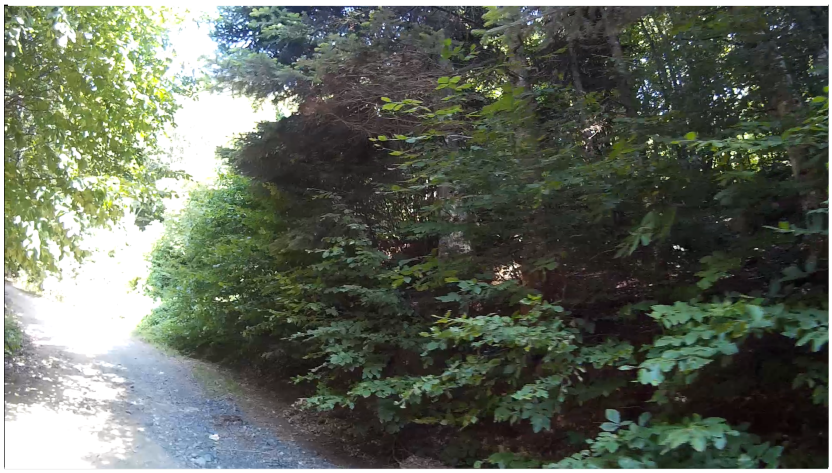
Digits ile veri seti oluşturma sırasında 256x256 piksel çözünürlük ve sıkıştırma modu tercih edilmiştir. Eğitimler yirmi epoch ve modellerin kendi batch büyüklükleri kullanılarak gerçekleştirilmiştir. Öğrenme hızı 0.001 olarak seçilmiştir.



(a) sol yönlü



(b) orta yönlü



(c) sağ yönlü

Şekil 5.4 Sağ, orta ve sol yönlü görüntü örnekleri

Bölümün devamında bulunan çizelgeler başarım oranlarını içermektedir. Farklı modellerin başarı oranlarının ve tepkilerinin ölçülmesi ile geliştirilecek sisteme uygunlukları test edilmiştir. Çizelge 5.1 ve Çizelge 5.2 üzerinde AlexNet ve GoogLeNet için Şekil 5.3 üzerinde görülen alandan toplanan test verileri ile elde edilen sonuçları görülmektedir. Test için kullanılan imgelerin, kaç adedinin doğru sınıfa atandığının tespiti ile başarı oranları oluşturulmuştur.

Düz doğrultu çok yüksek başarı oranına sahip iken, sol ve sağ doğrutular için başarım oranları yüzde yetmiş civarında elde edilmektedir. Yolun virajlı olduğu ve gün ışığının kameraya doğrudan vurduğu noktalarda başarımın düştüğü gözlenmiştir.

Çizelge 5.1 AlexNet modeli ile elde edilen test verisi sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Test Seti	Sol	3709	1296	1	%74.09
	Sağ	1668	3378	20	%66.68
	Orta	0	0	5709	%100

Çizelge 5.2 GoogLeNet modeli ile elde edilen test verisi sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Test Seti	Sol	3687	1310	9	%73.65
	Sağ	1140	3915	11	%77.28
	Orta	5619	90	0	%98.42

Çizelge 5.3, Çizelge 5.4 ve Çizelge 5.5 üzerinde AlexNet için Giusti vd., 2016 veri seti ile elde edilen test sonuçları görülmektedir.

Çizelge 5.3 AlexNet modeli ile elde edilen veri seti 10 sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Set 10	Sol	1864	278	49	%85.08
	Sağ	438	1547	205	%70.64
	Orta	5	4	2181	%99.59

Çizelge 5.4 AlexNet modeli ile elde edilen veri seti 11 sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Set 11	Sol	1774	221	2	%88.83
	Sağ	1105	827	64	%41.43
	Orta	519	303	1175	%58.84

Çizelge 5.5 AlexNet modeli ile elde edilen veri seti 12 sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Set 12	Sol	1799	286	2	%86.2
	Sağ	1834	241	12	%11.55
	Orta	354	536	1197	%57.36

Çizelge 5.6, Çizelge 5.7 ve Çizelge 5.8 üzerinde GoogLeNet için Giusti vd., 2016 veri seti ile elde edilen test sonuçları görülmektedir.

Çizelge 5.6 GoogLeNet modeli ile elde edilen veri seti 10 sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Set 10	Sol	1789	351	51	%81.65
	Sağ	426	1693	71	%77.31
	Orta	1	27	2162	%98.72

Çizelge 5.7 GoogLeNet modeli ile elde edilen veri seti 11 sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Set 11	Sol	1658	327	12	%83.02
	Sağ	871	1029	96	%51.55
	Orta	342	230	1425	%71.36

Çizelge 5.8 GoogLeNet modeli ile elde edilen veri seti 12 sonuçları

		Atanan Sınıf			**Başarılı Tespit Oranı**
		Sol	*Sağ*	*Orta*	
Set 12	Sol	1779	308	0	%85.24
	Sağ	1716	357	14	%17.11
	Orta	145	319	1623	%77.77

6. SONUÇ VE ÖNERİLER

Yön tahmini konusunda erişilen sonuçlar, GoogLeNet (Szegedy vd., 2014) modelinin kullanılan veri seti ile saha testlerine geçebilmek için istenilen başarı oranlarına ulaştığını göstermiştir.

AlexNet (Krizhevsky vd., 2012) modeli test sonuçları ile kıyaslandığında, GoogleNet başarı oranı ile öne çıkmaktadır. Bazı noktalarda aradaki farkın yüzde yirmi daha iyi olduğu görülebilir. GoogLeNet modelinde paralel olarak uygulanan modüllerin, bu uygulama için başarılı sonuç verdiği görülmüştür.

Model eğitimleri ve kıyaslaması çalışmasının dışında ayrıca ilgili modellerin hepsi TX2 kartı ile gömülü sistemde, kameradan canlı gelen veri ile çalışacak şekilde entegre edilmiştir. Saha testleri için gezgin robot üzerinde modellerin çalıştırılabileceği, grafik işlemcili bu kartın kullanılması önerilmektedir.

Çalışmanın bir adım ötesi olarak gerçek ortam testleri yapılmalıdır ve parametreler bu testler doğrultusunda optimize edilerek, kontrol kararı verilir hale getirilmelidir. Gerçek ortam testleri için TX2 kartının bir kontrol ünitesi ile birlikte kullanılması gerekmektedir. TX2 kart için mobil bir platformada kullanılabilecek taşıyıcı bir kart gerekmektedir. Piyasada yaygın olarak uyumlu kartlar bulunabilmektedir.

Gerçek ortam kullanımı için farklı sensör verilerinin birlikte değerlendirilerek kullanılması önerilmektedir. Literatürde birçok örneği olan bu durumun, başarı oranını arttırması muhtemeldir.

Tez çalışması sonucunda, model eğitimleri ve optimizasyonları ile ortaya çıkan model dosyaları hem mobil robotlar hem de dronelar için navigasyon uygulaması geliştirmesi için kullanılabilir.

KAYNAKLAR DİZİNİ

Alvarez, H., Paz, L. M., Sturm, J. ve Cremers, D. (2016), Collision Avoidance for Quadrotors with a Monocular Camera, Springer, Cham, 195–209. DOI: 10.1007/978-3-319-23778-7_14. URL: http://link.springer.com/10.1007/978-3-319-23778-7{_}14.

Badrinarayanan, V., Kendall, A. ve Cipolla, R. (2017), SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence* 39.12, 2481–2495. ISSN: 01628828. DOI: 10.1109/TPAMI.2016.2644615. arXiv: 1511.00561.

Boston Dynamics (2017), LS3 Legged Squad Support Systems, *Boston Dynamics Advertisement Material*.

Cameron, J. (1991), Terminator 2: Judgment Day, *Carolco Pictures Pacific Western Productions Lightstorm Entertainment Le Studio Canal+ S.A.*

Chacra, D. A. ve Zelek, J. (2016), Road Segmentation in Street View Images Using Texture Information, *2016 13th Conference on Computer and Robot Vision (CRV)*. IEEE, 424–431. ISBN: 978-1-5090-2491-9. DOI: 10.1109/CRV.2016.47. URL: http://ieeexplore.ieee.org/document/7801553/.

Chaib, K., Hamerlain, M., Achour, N. ve Nemra, A. (2017), Visual Odometry with loop closing detection using Iterative Closest SURF Point, *2017 6th International Conference on Systems and Control (ICSC)*. IEEE, 503–508. ISBN: 978-1-5090-3960-9. DOI: 10.1109/ICoSC.2017.7958677. URL: http://ieeexplore.ieee.org/document/7958677/.

Chang, C.-K., Siagian, C. ve Itti, L. (2012), Mobile robot monocular vision navigation based on road region and boundary estimation, *2012 IEEE/RSJ International Conference on*

KAYNAKLAR DİZİNİ (devam)

Intelligent Robots and Systems. IEEE, 1043–1050. ISBN: 978-1-4673-1736-8. DOI: 10.1109/IROS.2012.6385703. URL: http://ieeexplore.ieee.org/document/6385703/.

Chen, M., Cai, Z. ve Wang, Y. (2012), A method for mobile robot obstacle avoidance based on stereo vision, *IEEE 10th International Conference on Industrial Informatics*. IEEE, 94–98. ISBN: 978-1-4673-0311-8. DOI: 10.1109/INDIN.2012.6300848. URL: http://ieeexplore.ieee.org/document/6300848/.

Chen, W., Fang, M., Liu, Y.-H. ve Li, L. (2017), Monocular semantic SLAM in dynamic street scene based on multiple object tracking, *2017 IEEE International Conference on Cybernetics and Intelligent Systems (CIS) and IEEE Conference on Robotics, Automation and Mechatronics (RAM)*. IEEE, 599–604. ISBN: 978-1-5386-3135-5. DOI: 10.1109/ICCIS.2017.8274845. URL: http://ieeexplore.ieee.org/document/8274845/.

Cherubini, A. ve Chaumette, F. (2010), A redundancy-based approach for obstacle avoidance in mobile robot navigation, *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, 5700–5705. ISBN: 978-1-4244-6674-0. DOI: 10.1109/IROS.2010.5650395. URL: http://ieeexplore.ieee.org/document/5650395/.

Cherubini, A., Spindler, F. ve Chaumette, F. (2011), A redundancy-based approach for visual navigation with collision avoidance, *2011 IEEE Symposium on Computational Intelligence in Vehicles and Transportation Systems (CIVTS) Proceedings*. IEEE, 8–15. ISBN: 978-1-4244-9975-5. DOI: 10.1109/CIVTS.2011.5949530. URL: http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5949530.

Cherubini, A., Spindler, F. ve Chaumette, F. (2014), Autonomous Visual Navigation and Laser-Based Moving Obstacle Avoidance, *IEEE Transactions on Intelligent Transportation Systems*. **volume** 15. 5, 2101–2110. DOI: 10.1109/TITS.2014.2308977. URL: http://ieeexplore.ieee.org/document/6782420/.

KAYNAKLAR DİZİNİ (devam)

Cigla, C., Brockers, R. ve Matthies, L. (2017), Image-Based Visual Perception and Representation for Collision Avoidance, *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. IEEE, 421–429. ISBN: 978-1-5386-0733-6. DOI: 10.1109/CVPRW.2017.57. URL: http://ieeexplore.ieee.org/document/8014791/.

Costante, G., Mancini, M., Valigi, P. ve Ciarfuglia, T. A. (2016), Exploring Representation Learning With CNNs for Frame-to-Frame Ego-Motion Estimation, *IEEE Robotics and Automation Letters* 1.1, 18–25. ISSN: 2377-3766. DOI: 10.1109/LRA.2015.2505717. URL: http://ieeexplore.ieee.org/document/7347378/.

Crisman, J. ve Thorpe, C. (1993), SCARF: a color vision system that tracks roads and intersections, *IEEE Transactions on Robotics and Automation* 9.1, 49–58. ISSN: 1042296X. DOI: 10.1109/70.210794. URL: http://ieeexplore.ieee.org/document/210794/.

Deepika, N. ve Sajith Variyar, V. V. (2017), Obstacle classification and detection for vision based navigation for autonomous driving, *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. IEEE, 2092–2097. ISBN: 978-1-5090-6367-3. DOI: 10.1109/ICACCI.2017.8126154. URL: http://ieeexplore.ieee.org/document/8126154/.

Delgado, V. J., Kurka, P. R. ve Cardozo, E. (2011), Visual odometry in mobile robots, *IX Latin American Robotics Symposium and IEEE Colombian Conference on Automatic Control, 2011 IEEE*. IEEE, 1–4. ISBN: 978-1-4577-1691-1. DOI: 10.1109/LARC.2011.6086813. URL: http://ieeexplore.ieee.org/document/6086813/.

Di Fava, A., Satler, M. ve Tripicchio, P. (2015), Visual navigation of mobile robots for autonomous patrolling of indoor and outdoor areas, *2015 23rd Mediterranean Conference on Control and Automation (MED)*. IEEE, 667–674. ISBN:

KAYNAKLAR DİZİNİ (devam)

978-1-4799-9936-1. DOI: 10 . 1109 / MED . 2015 . 7158823. URL: http://ieeexplore.ieee.org/document/7158823/.

Dionisio-Ortega, S., Rojas-Perez, L. O., Martinez-Carranza, J. ve Cruz-Vega, I. (2018), A deep learning approach towards autonomous flight in forest environments, *2018 International Conference on Electronics, Communications and Computers (CONIELECOMP)*. IEEE, 139–144. ISBN: 978-1-5386-2363-3. DOI: 10 . 1109 / CONIELECOMP . 2018 . 8327189. URL: http://ieeexplore.ieee.org/document/8327189/.

Eraghi, N. O., Lopez-Colino, F., Castro, A. de ve Garrido, J. (2015), NafisNav: An indoor navigation algorithm for embedded systems and based on grid maps, *2015 IEEE International Conference on Industrial Technology (ICIT)*. IEEE, 345–350. ISBN: 978-1-4799-7800-7. DOI: 10 . 1109 / ICIT . 2015 . 7125122. URL: http : //ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7125122.

Fen, X. ve Zhen, W. (2015), An embedded visual SLAM algorithm based on Kinect and ORB features, *2015 34th Chinese Control Conference (CCC)*. IEEE, 6026–6031. ISBN: 978-9-8815-6389-7. DOI: 10.1109/ChiCC.2015.7260583. URL: http://ieeexplore.ieee.org/document/7260583/.

Furuta, Y., Wada, K., Murooka, M., Nozawa, S., Kakiuchi, Y., Okada, K. ve Inaba, M. (2016), Transformable semantic map based navigation using autonomous deep learning object segmentation, *2016 IEEE-RAS 16th International Conference on Humanoid Robots (Humanoids)*. IEEE, 614–620. ISBN: 978-1-5090-4718-5. DOI: 10 . 1109 / HUMANOIDS . 2016 . 7803338. URL: http://ieeexplore.ieee.org/document/7803338/.

Garcia, A. ve Ghose, K. (2017), Autonomous indoor navigation of a stock quadcopter with off-board control, *2017 Workshop on Research, Education and Development of Unmanned Aerial Systems (RED-UAS)*. IEEE, 132–137. ISBN: 978-1-5386-0939-2. DOI:

KAYNAKLAR DİZİNİ (devam)

10 . 1109 / RED - UAS . 2017 . 8101656. URL: http://ieeexplore.ieee.org/document/8101656/.

Giusti, A., Guzzi, J., Ciresan, D. C., He, F.-L., Rodriguez, J. P., Fontana, F., Faessler, M., Forster, C., Schmidhuber, J., Caro, G. D., Scaramuzza, D. ve Gambardella, L. M. (2016), A Machine Learning Approach to Visual Perception of Forest Trails for Mobile Robots, *IEEE Robotics and Automation Letters* 1.2, 661–667. ISSN: 2377-3766. DOI: 10.1109/LRA.2015.2509024. URL: http://ieeexplore.ieee.org/document/7358076/.

Grisetti, G., Stachniss, C. ve Burgard, W. (2007), Improved techniques for grid mapping with Rao-Blackwellized particle filters, *IEEE Transactions on Robotics* 23.1, 34–46. ISSN: 15523098. DOI: 10.1109/TRO.2006.889486.

Gupta, M., Kumar, S., Kejriwal, N., Behera, L. ve Venkatesh, K. S. (2015), SURF-based human tracking algorithm for a human-following mobile robot, *2015 International Conference on Image Processing Theory, Tools and Applications (IPTA)*. IEEE, 111–116. ISBN: 978-1-4799-8636-1. DOI: 10 . 1109 / IPTA . 2015 . 7367107. URL: http://ieeexplore.ieee.org/document/7367107/.

Hagiwara, Y., Inamura, T. ve Choi, Y. (2013), Effectiveness evaluation of view-based navigation for obstacle avoidance, *2013 13th International Conference on Control, Automation and Systems (ICCAS 2013)*. IEEE, 1029–1033. ISBN: 978-89-93215-05-2. DOI: 10 . 1109 / ICCAS . 2013 . 6704068. URL: http://ieeexplore.ieee.org/document/6704068/.

Hane, C., Zach, C., Jongwoo Lim, Ranganathan, A. ve Pollefeys, M. (2011), Stereo depth map fusion for robot navigation, *2011 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, 1618–1625. ISBN: 978-1-61284-456-5. DOI: 10.1109/IROS.2011.6094704. URL: http://ieeexplore.ieee.org/document/6094704/.

KAYNAKLAR DİZİNİ (devam)

He, K., Zhang, X., Ren, S. ve Sun, J. (2015), Deep Residual Learning for Image Recognition, *CoRR* abs/1512.03385. arXiv: 1512.03385. URL: http://arxiv.org/abs/1512.03385.

Hernandez, A. C., Gomez, C., Crespo, J. ve Barber, R. (2017), Adding Uncertainty to an Object Detection System for Mobile Robots, *2017 6th International Conference on Space Mission Challenges for Information Technology (SMC-IT)*. IEEE, 7–12. ISBN: 978-1-5386-3462-2. DOI: 10.1109/SMC-IT.2017.9. URL: http://ieeexplore.ieee.org/document/8227532/.

Hossein Bamorovat Abadi, M., Oskoei, M. A. ve Fakharian, A. (2015), Mobile robot navigation using sonar vision algorithm applied to omnidirectional vision, *2015 AI & Robotics (IRANOPEN)*. IEEE, 1–6. ISBN: 978-1-4799-8733-7. DOI: 10.1109/RIOS.2015.7270728. URL: http://ieeexplore.ieee.org/document/7270728/.

Hu, S., Cao, C. ve Pan, J. (2017), Deep-learned pedestrian avoidance policy for robot navigation, *2017 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. IEEE, 338–343. ISBN: 978-1-5386-3742-5. DOI: 10.1109/ROBIO.2017.8324440. URL: http://ieeexplore.ieee.org/document/8324440/.

Huang, P.-T., Li, C.-Y., Hsu, C.-C. ve Hong, C.-M. (2012), Object following based on SURF for mobile robots, *The 1st IEEE Global Conference on Consumer Electronics 2012*. IEEE, 382–386. ISBN: 978-1-4673-1501-2. DOI: 10.1109/GCCE.2012.6379634. URL: http://ieeexplore.ieee.org/document/6379634/.

Huang, Y.-P., Sithole, L. ve Lee, T.-T. (2017), Structure From Motion Technique for Scene Detection Using Autonomous Drone Navigation, *IEEE Transactions on Systems, Man,*

KAYNAKLAR DİZİNİ (devam)

and Cybernetics: Systems, 1–12. ISSN: 2168-2216. DOI: 10.1109/TSMC.2017.2745419. URL: http://ieeexplore.ieee.org/document/8038234/.

Hui, X., Bian, J., Yu, Y., Zhao, X. ve Tan, M. (2017), A novel autonomous navigation approach for UAV power line inspection, *2017 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. IEEE, 634–639. ISBN: 978-1-5386-3742-5. DOI: 10.1109/ROBIO.2017.8324488. URL: http://ieeexplore.ieee.org/document/8324488/.

Jung, S., Hwang, S., Shin, H. ve Shim, D. H. (2018), Perception, Guidance, and Navigation for Indoor Autonomous Drone Racing Using Deep Learning, *IEEE Robotics and Automation Letters* 3.3, 2539–2544. ISSN: 2377-3766. DOI: 10.1109/LRA.2018.2808368. URL: http://ieeexplore.ieee.org/document/8299437/.

Kato, Y., Kamiyama, K. ve Morioka, K. (2017), Autonomous robot navigation system with learning based on deep Q-network and topological maps, *2017 IEEE/SICE International Symposium on System Integration (SII)*. IEEE, 1040–1046. ISBN: 978-1-5386-2263-6. DOI: 10.1109/SII.2017.8279360. URL: http://ieeexplore.ieee.org/document/8279360/.

Khalilullah, K. M. I., Ota, S., Yasuda, T. ve Jindai, M. (2017), Development of robot navigation method based on single camera vision using deep learning, *2017 56th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*. IEEE, 939–942. ISBN: 978-4-907764-57-9. DOI: 10.23919/SICE.2017.8105675. URL: http://ieeexplore.ieee.org/document/8105675/.

Kim, J.-H., Jang, K.-J. ve Jang, J.-W. (2017), Dynamic object tracing method for mobile robot by fusing visual features, *2017 56th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*. IEEE, 862–864. ISBN: 978-4-907764-57-9. DOI: 10.23919/SICE.2017.8105776. URL: http://ieeexplore.ieee.org/document/8105776/.

KAYNAKLAR DİZİNİ (devam)

Kim, Y.-H., Jang, J.-I. ve Yun, S. (2018), End-to-end deep learning for autonomous navigation of mobile robot, *2018 IEEE International Conference on Consumer Electronics (ICCE)*. IEEE, 1–6. ISBN: 978-1-5386-3025-9. DOI: 10.1109/ICCE.2018.8326229. URL: http://ieeexplore.ieee.org/document/8326229/.

Krajnik, T., Blazicek, J. ve Santos, J. M. (2015), Visual road following using intrinsic images, *2015 European Conference on Mobile Robots (ECMR)*. IEEE, 1–6. ISBN: 978-1-4673-9163-4. DOI: 10.1109/ECMR.2015.7324212. URL: http://ieeexplore.ieee.org/document/7324212/.

Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2012), *ImageNet Classification with Deep Convolutional Neural Networks*. URL: http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional.

Kuang, H., Zhang, K., Li, R. ve Liu, X. (2018), Monocular SLAM Algorithm Based on Improved Depth Map Estimation and Keyframe Selection, *2018 10th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA)*. IEEE, 350–353. ISBN: 978-1-5386-5114-8. DOI: 10.1109/ICMTMA.2018.00091. URL: https://ieeexplore.ieee.org/document/8337402/.

Lee, J., Lu, Y., Xu, Y. ve Song, D. (2016), Visual programming for mobile robot navigation using high-level landmarks, *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2901–2906. ISBN: 978-1-5090-3762-9. DOI: 10.1109/IROS.2016.7759449. URL: http://ieeexplore.ieee.org/document/7759449/.

Li, H., Hu, Z. ve Chen, X. (2016a), Robust monocular visual odometry using optical flows for mobile robots, *2016 35th Chinese Control Conference (CCC)*. IEEE, 6003–6007. ISBN:

KAYNAKLAR DİZİNİ (devam)

978-9-8815-6391-0. DOI: 10.1109/ChiCC.2016.7554300. URL: http://ieeexplore.ieee.org/document/7554300/.

Li, R., Wei, L., Gu, D., Hu, H. ve McDonald-Maier, K. D. (2013a), Multi-layered map based navigation and interaction for an intelligent wheelchair, *2013 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. IEEE, 115–120. ISBN: 978-1-4799-2744-9. DOI: 10.1109/ROBIO.2013.6739445. URL: http://ieeexplore.ieee.org/document/6739445/.

Li, X., Wang, Q. ve Zhang, X. (2013b), Application of Electronic Compass and Vision-Based Camera in Robot Navigation and Map Building, *2013 IEEE 9th International Conference on Mobile Ad-hoc and Sensor Networks*. IEEE, 546–549. ISBN: 978-1-4799-3429-4. DOI: 10.1109/MSN.2013.101. URL: http://ieeexplore.ieee.org/document/6726394/.

Li, X. ve Wang, J. (2012), Multi-image matching for 3D mapping in vision-based navigation applications, *2012 Ubiquitous Positioning, Indoor Navigation, and Location Based Service (UPINLBS)*. IEEE, 1–8. ISBN: 978-1-4673-1909-6. DOI: 10.1109/UPINLBS.2012.6409766. URL: http://ieeexplore.ieee.org/document/6409766/.

Li, Y., Sun, Z., Xu, Y. ve Zhang, B. (2015), Robot navigation based on visual feature perception and Monte Carlo sampling, *The 27th Chinese Control and Decision Conference (2015 CCDC)*. IEEE, 3237–3242. ISBN: 978-1-4799-7017-9. DOI: 10.1109/CCDC.2015.7162478. URL: http://ieeexplore.ieee.org/document/7162478/.

Li, Y., Zhang, Z., Li, J. ve Liu, Y. (2016b), Outdoor image region recognition based on MS-OS-BOW model, *2016 5th International Conference on Computer Science and Network Technology (ICCSNT)*. IEEE, 800–805. ISBN: 978-1-5090-2129-1. DOI: 10.1109/ICCSNT.2016.8070269. URL: http://ieeexplore.ieee.org/document/8070269/.

KAYNAKLAR DİZİNİ (devam)

Liau, Y. S., Zhang, Q., Li, Y. ve Ge, S. S. (2012), Non-metric navigation for mobile robot using optical flow, *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, 4953–4958. ISBN: 978-1-4673-1736-8. DOI: 10.1109/IROS.2012.6386221. URL: http://ieeexplore.ieee.org/document/6386221/.

Lin, J., Wang, W.-J., Huang, S.-K. ve Chen, H.-C. (2017a), Learning based semantic segmentation for robot navigation in outdoor environment, *2017 Joint 17th World Congress of International Fuzzy Systems Association and 9th International Conference on Soft Computing and Intelligent Systems (IFSA-SCIS)*. IEEE, 1–5. ISBN: 978-1-5090-4917-2. DOI: 10.1109/IFSA-SCIS.2017.8023347. URL: http://ieeexplore.ieee.org/document/8023347/.

Lin, J., Wang, W.-J., Huang, S.-K. ve Chen, H.-C. (2017b), Learning based semantic segmentation for robot navigation in outdoor environment, *2017 Joint 17th World Congress of International Fuzzy Systems Association and 9th International Conference on Soft Computing and Intelligent Systems (IFSA-SCIS)*. IEEE, 1–5. ISBN: 978-1-5090-4917-2. DOI: 10.1109/IFSA-SCIS.2017.8023347. URL: http://ieeexplore.ieee.org/document/8023347/.

Luo, C., Gao, J., Li, X., Mo, H. ve Jiang, Q. (2014), Sensor-based autonomous robot navigation under unknown environments with grid map representation, *2014 IEEE Symposium on Swarm Intelligence*. IEEE, 1–7. ISBN: 978-1-4799-4458-3. DOI: 10.1109/SIS.2014.7011782. URL: http://ieeexplore.ieee.org/document/7011782/.

Martinson, E. ve Yalla, V. (2016), Real-time human detection for robots using CNN with a feature-based layered pre-filter, *2016 25th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*. IEEE, 1120–1125. ISBN: 978-1-5090-3929-6. DOI: 10.1109/ROMAN.2016.7745248. URL: http://ieeexplore.ieee.org/document/7745248/.

KAYNAKLAR DİZİNİ (devam)

McGuire, K., Croon, G. de, De Wagter, C., Tuyls, K. ve Kappen, H. (2017), Efficient Optical Flow and Stereo Vision for Velocity Estimation and Obstacle Avoidance on an Autonomous Pocket Drone, *IEEE Robotics and Automation Letters* 2.2, 1070–1076. ISSN: 2377-3766. DOI: 10.1109/LRA.2017.2658940. URL: http://ieeexplore.ieee.org/document/7833065/.

Mei, W., Pan, W. ve Xie, L. (2012), Semantic-understand-based landmark navigation method of robots, *2012 IEEE International Conference on Computer Science and Automation Engineering (CSAE)*. IEEE, 760–764. ISBN: 978-1-4673-0089-6. DOI: 10.1109/CSAE.2012.6272702. URL: http://ieeexplore.ieee.org/document/6272702/.

Moreno-Armendariz, M. A. ve Calvo, H. (2014), Visual SLAM and Obstacle Avoidance in Real Time for Mobile Robots Navigation, *2014 International Conference on Mechatronics, Electronics and Automotive Engineering*. IEEE, 44–49. ISBN: 978-1-4673-6756-1. DOI: 10.1109/ICMEAE.2014.12. URL: http://ieeexplore.ieee.org/document/7120844/.

Munguia-Silva, R. ve Martinez-Carranza, J. (2018), Autonomous flight using RGB-D SLAM with a monocular onboard camera only, *2018 International Conference on Electronics, Communications and Computers (CONIELECOMP)*. IEEE, 200–206. ISBN: 978-1-5386-2363-3. DOI: 10.1109/CONIELECOMP.2018.8327199. URL: http://ieeexplore.ieee.org/document/8327199/.

NASA Facts National Aeronautics and Space Administration (2004), Mars Exploration Rover, *Jet Propulsion Laboratory California Institute of Technology*.

NVIDIA (2016), Jetson TX2 Developer Kit, *NVIDIA Advertisement Material*.

KAYNAKLAR DİZİNİ (devam)

Nilsson, N. J. (1969), A Mobile Automaton: An Application of Artificial Intelligence Techniques, *Proc. of Intl. Joint Conf. on Artificial Intelligence*.

Ryu, J., Zhang, D. ve Nishimura, T. (2008), Robust Feature Detection for a Mobile Robot using a Multi-View Single Camera, *2008 IEEE/SICE International Symposium on System Integration*. IEEE, 105–110. ISBN: 978-1-4244-3838-9. DOI: 10.1109/SI.2008.4770435. URL: http://ieeexplore.ieee.org/document/4770435/.

Schaub, A. ve Burschka, D. (2017), Single Point Velocity Estimation in dynamic scenes from optical flow in binocular systems, *2017 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)*. IEEE, 193–200. ISBN: 978-1-5090-5998-0. DOI: 10.1109/AIM.2017.8014017. URL: http://ieeexplore.ieee.org/document/8014017/.

Shene, T., Sridharan, K. ve Sudha, N. (2016), Real-Time SURF-Based Video Stabilization System for an FPGA-Driven Mobile Robot, *IEEE Transactions on Industrial Electronics*, 1–1. ISSN: 0278-0046. DOI: 10.1109/TIE.2016.2551684. URL: http://ieeexplore.ieee.org/document/7448903/.

Smolyanskiy, N., Kamenev, A., Smith, J. ve Birchfield, S. (2017), Toward low-flying autonomous MAV trail navigation using deep neural networks for environmental awareness, *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 4241–4247. ISBN: 978-1-5386-2682-5. DOI: 10.1109/IROS.2017.8206285. URL: http://ieeexplore.ieee.org/document/8206285/.

Soltani, H., Taghirad, H. D. ve Norouzzadeh Ravari, A. (2012), Stereo-based visual navigation of mobile robots in unknown environments, *20th Iranian Conference on Electrical Engineering (ICEE2012)*. IEEE, 946–951. ISBN: 978-1-4673-1148-9. DOI:

KAYNAKLAR DİZİNİ (devam)

10 . 1109 / IranianCEE . 2012 . 6292489. URL: http://ieeexplore.ieee.org/document/6292489/.

Stauffer, C. ve Grimson, W. E. L. (1999), Adaptive background mixture models for real-time tracking, *Proceedings 1999 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Cat No PR00149* 2.c, 246–252. ISSN: 10636919. DOI: 10.1109/CVPR.1999.784637. arXiv: CVPR.1999.784637 [10.1109]. URL: http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=784637.

Sun, S., Li, T. ve Sattar, T. (2013), Adapting sample size in particle filters through KLD-resampling, *Electronics Letters* 49.12, 740–742. ISSN: 0013-5194. DOI: 10.1049/el.2013.0233. URL: http://digital-library.theiet.org/content/journals/10.1049/el.2013.0233.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A. (2014), Going Deeper with Convolutions, arXiv: 1409.4842. URL: http://arxiv.org/abs/1409.4842.

Tai, L., Paolo, G. ve Liu, M. (2017), Virtual-to-real deep reinforcement learning: Continuous control of mobile robots for mapless navigation, *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 31–36. ISBN: 978-1-5386-2682-5. DOI: 10 . 1109 / IROS . 2017 . 8202134. URL: http://ieeexplore.ieee.org/document/8202134/.

Wang, C., Meng, L., She, S., Mitchell, I. M., Li, T., Tung, F., Wan, W., Meng, M. Q.-H. ve Silva, C. W. de (2017a), Autonomous mobile robot navigation in uneven and unstructured indoor environments, *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 109–116. ISBN: 978-1-5386-2682-5. DOI: 10.1109/IROS.2017.8202145. URL: http://ieeexplore.ieee.org/document/8202145/.

KAYNAKLAR DİZİNİ (devam)

Wang, W., Wang, N., Wu, X., You, S. ve Neumann, U. (2017b), Self-paced cross-modality transfer learning for efficient road segmentation, *2017 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 1394–1401. ISBN: 978-1-5090-4633-1. DOI: 10.1109/ICRA.2017.7989166. URL: http://ieeexplore.ieee.org/document/7989166/.

Wang, Y. ve Dong, Q. (2016), Using Optical Flow with Principal Divection Screen Strategy for Road Navigation, *2016 9th International Symposium on Computational Intelligence and Design (ISCID)*. IEEE, 52–55. ISBN: 978-1-5090-3558-8. DOI: 10.1109/ISCID.2016.2021. URL: http://ieeexplore.ieee.org/document/7830790/.

Xin, J., Jiao, X.-L., Yang, Y. ve Liu, D. (2016a), Visual navigation for mobile robot with Kinect camera in dynamic environment, *2016 35th Chinese Control Conference (CCC)*. IEEE, 4757–4764. ISBN: 978-9-8815-6391-0. DOI: 10.1109/ChiCC.2016.7554091. URL: http://ieeexplore.ieee.org/document/7554091/.

Xin, J., Jiao, X.-L., Yang, Y. ve Liu, D. (2016b), Visual navigation for mobile robot with Kinect camera in dynamic environment, *2016 35th Chinese Control Conference (CCC)*. IEEE, 4757–4764. ISBN: 978-9-8815-6391-0. DOI: 10.1109/ChiCC.2016.7554091. URL: http://ieeexplore.ieee.org/document/7554091/.

Xin, J., Zhao, H., Liu, D. ve Li, M. (2017), Application of deep reinforcement learning in mobile robot path planning, *2017 Chinese Automation Congress (CAC)*. IEEE, 7112–7116. ISBN: 978-1-5386-3524-7. DOI: 10.1109/CAC.2017.8244061. URL: http://ieeexplore.ieee.org/document/8244061/.

Xiong, Y., Zhang, X., Peng, J. ve Yu, W. (2017), 3D depth map based optimal motion control for wheeled mobile robot, *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. IEEE, 2045–2050. ISBN: 978-1-5386-1645-1. DOI: 10.1109/SMC.2017.8122920. URL: http://ieeexplore.ieee.org/document/8122920/.

KAYNAKLAR DİZİNİ (devam)

Yong Zhu, Changguo Sun, Zhixin Han ve Chaofa Yu (2011), A visual navigation algorithm for mobile robot in semi-structured environment, *2011 IEEE International Conference on Computer Science and Automation Engineering*. IEEE, 716–721. ISBN: 978-1-4244-8727-1. DOI: 10.1109/CSAE.2011.5952604. URL: http://ieeexplore.ieee.org/document/5952604/.

Yuan, W., Li, Z. ve Su, C.-Y. (2016), RGB-D sensor-based visual SLAM for localization and navigation of indoor mobile robot, *2016 International Conference on Advanced Robotics and Mechatronics (ICARM)*. IEEE, 82–87. ISBN: 978-1-5090-3364-5. DOI: 10.1109/ICARM.2016.7606899. URL: http://ieeexplore.ieee.org/document/7606899/.

Zhang, J., Kantor, G., Bergerman, M. ve Singh, S. (2012), Monocular visual navigation of an autonomous vehicle in natural scene corridor-like environments, *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, 3659–3666. ISBN: 978-1-4673-1736-8. DOI: 10.1109/IROS.2012.6385479. URL: http://ieeexplore.ieee.org/document/6385479/.

Zhang, Y., Wang, H. ve Xu, F. (2017), Object detection and recognition of intelligent service robot based on deep learning, *2017 IEEE International Conference on Cybernetics and Intelligent Systems (CIS) and IEEE Conference on Robotics, Automation and Mechatronics (RAM)*. IEEE, 171–176. ISBN: 978-1-5386-3135-5. DOI: 10.1109/ICCIS.2017.8274769. URL: http://ieeexplore.ieee.org/document/8274769/.

Zhilenkov, A. A. ve Epifantsev, I. R. (2018), System of autonomous navigation of the drone in difficult conditions of the forest trails, *2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*. IEEE, 1036–1039. ISBN: 978-1-5386-4339-6. DOI: 10.1109/EIConRus.2018.8317266. URL: http://ieeexplore.ieee.org/document/8317266/.

KAYNAKLAR DİZİNİ (devam)

Zhong, F., Wang, S., Zhang, Z., Chen, C. ve Wang, Y. (2018), Detect-SLAM: Making Object Detection and SLAM Mutually Beneficial, *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*. IEEE, 1001–1010. ISBN: 978-1-5386-4886-5. DOI: 10.1109/WACV.2018.00115. URL: https://ieeexplore.ieee.org/document/8354219/.

Zhongli Wang ve Jie Zhao (2011), Optical flow based plane detection for mobile robot navigation, *2011 9th World Congress on Intelligent Control and Automation*. IEEE, 1156–1160. ISBN: 978-1-61284-698-9. DOI: 10.1109/WCICA.2011.5970697. URL: http://ieeexplore.ieee.org/document/5970697/.

Zhu, Y., Mottaghi, R., Kolve, E., Lim, J. J., Gupta, A., Fei-Fei, L. ve Farhadi, A. (2017), Target-driven visual navigation in indoor scenes using deep reinforcement learning, *2017 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 3357–3364. ISBN: 978-1-5090-4633-1. DOI: 10.1109/ICRA.2017.7989381. URL: http://ieeexplore.ieee.org/document/7989381/.

Zsedrovits, T., Zarandy, A., Vanek, B., Peni, T., Bokor, J. ve Roska, T. (2011), Collision avoidance for UAV using visual detection, *2011 IEEE International Symposium of Circuits and Systems (ISCAS)*. IEEE, 2173–2176. ISBN: 978-1-4244-9473-6. DOI: 10.1109/ISCAS.2011.5938030. URL: http://ieeexplore.ieee.org/document/5938030/.