



## **GÖRÜNTÜ İŞLEME TABANLI ARAÇTAN ARACA MESAFE TAHMİNİ**

**ÖZGÜR DURAN**

**YÜKSEK LİSANS TEZİ**

**MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**Dr. Öğr. Üyesi Bülent TURAN**

**Aralık - 2020**

**Her hakkı saklıdır**

T.C.  
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**GÖRÜNTÜ İŞLEME TABANLI ARAÇTAN ARACA MESAFE  
TAHMİNİ**

**ÖZGÜR DURAN**

TOKAT  
Aralık - 2020

Her hakkı saklıdır

**Özgür DURAN** tarafından hazırlanan “**Görüntü İşleme Tabanlı Araçtan Araca Mesafe Tahmini**” adlı tez çalışmasının savunma sınavı 10 ARALIK 2020 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü **MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Dr. Öğr. Üyesi Bülent TURAN

Tokat Gaziosmanpaşa Üniversitesi

.....

Üye

Dr. Öğr. Üyesi Mahir KAYA

Tokat Gaziosmanpaşa Üniversitesi

.....

Üye

Dr. Öğr. Üyesi Yavuz ÜNAL

Amasya Üniversitesi

.....

ONAY

.....

Prof. Dr. Mehmet GÜNEŞ  
Lisansüstü Eğitim Enstitüsü Müdürü

---/---/20--

## **TEZ BEYANI**

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdiği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

**ÖZGÜR DURAN**

**10 Aralık 2020**

## ÖZET

### YÜKSEK LİSANS TEZİ

#### GÖRÜNTÜ İŞLEME TABANLI ARAÇTAN ARACA MESAFE TAHMİNİ

ÖZGÜR DURAN

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: DR. ÖĞR. ÜYESİ BÜLENT TURAN)

Araç sürücülerini için öndeki araçla olan mesafelerinin güvenli sayılabilecek uzaklıkta olması sürüş güvenliği açısından önemlidir. Bu çalışmada öndeki araçla olan mesafeyi tahmin etmek için bir yöntem sunulmuştur. Önerilen yöntemin uygulanması için, bir aracın üzerinde bulunan tavan barının uçlarına monte edilen iki kamera kullanılmaktadır. Kameraların optik eksenleri, birbirlerine doğru eşit oranda eğimlidir ve birbiriyle kesişmektedir. Çalışmada öndeki aracın mesafesini tahmin etmek için bir Yapay Sinir Ağı (YSA) modeli geliştirilmiştir. Veri seti oluşturmak için öndeki aracın plaka bölgesi merkez noktasının kameraların görüntülerindeki koordinatlarından elde edilen bilgiler kullanılmaktadır. Bu amaçla öndeki aracın farklı yatay konum ve uzaklıklarından alınan 414 adet görüntü örneği çifti kullanılmıştır. Bu görüntü örneklerinden 352 tanesi eğitim veri seti, 62 tanesi ise test veri seti için kullanılmıştır. En iyi sonucu veren; giriş değişkenleri, nöron sayısı ve iterasyon sayısına sahip YSA modelini belirlemek amacıyla denemeler yapılmıştır. Yapılan denemelerde hedef noktanın kamera görüntülerindeki yatay ve dikey koordinat bilgilerinden oluşturulan sekiz parametrenin giriş değişkenleri olarak kullanıldığı YSA modeli en iyi sonucu vermiştir. Bu sonuç önerilen yöntemde öndeki araca ait kamera görüntülerindeki yatay ve dikey konum farklarının mesafe tahmininde belirleyici olduğunu göstermektedir. Bir sınırlama olarak, hedef noktanın tespiti manuel olarak yapılmıştır. Böylece önerilen metodolojinin hedef noktanın tespitinden bağımsız olarak değerlendirilmesi gerçekleştirilmiştir. Belirlenen YSA modeliyle test verilerinden elde edilen sonuçlara ait ortalama mutlak yüzde hatası değeri %1.6961 olarak belirlenmiştir. Sonuç olarak önerilen metodolojinin araçtan araca mesafe tespitinde etkin olduğu görülmektedir.

2020, 110 SAYFA

**ANAHTAR KELİMELELER:** Görüntü İşleme, Yapay Sinir Ağları, Mesafe Tahmini, Stereo Kamera

## **ABSTRACT**

### **MASTER THESIS**

#### **IMAGE PROCESSING BASED VEHICLE TO VEHICLE DISTANCE ESTIMATION**

**ÖZGÜR DURAN**

**TOKAT GAZIOSMANPASA UNIVERSITY  
INSTITUTE OF GRADUATE STUDIES**

**DEPARTMENT OF MECHATRONICS ENGINEERING**

**(SUPERVISOR: ASST. PROF. DR. BÜLENT TURAN)**

It is important for vehicle drivers that their distance from the vehicle in front is safe to be considered. In this study, a method is presented to estimate the distance to the vehicle in front. For the implementation of the proposed method, two cameras mounted at the ends of the roof bar on a vehicle are used. The optical axes of the cameras are equally inclined towards each other and intersect with each other. In the study, an Artificial Neural Network (ANN) model was developed to estimate the distance of the vehicle in front. To create a data set, information obtained from the coordinates in the camera images of the center point of the plate of the vehicle in front is used. For this purpose, 414 pairs of image samples taken from different horizontal positions and distances of the vehicle in front were used. 352 of these image samples were used for the training data set and 62 for the test data set. Attempts were made to determine the input variables, the number of neurons and the number of iterations of the ANN model, which gave the best results. In the experiments, ANN model, which uses the eight parameters created from the horizontal and vertical coordinate information in the camera images of the target point as input variables, gave the best results. This result shows that the difference between horizontal and vertical positions in the camera images of the vehicle in the proposed method is determinant in the distance estimation. The limitation of the proposed method was that the detection of the target point was done manually. With the determined ANN model, the mean absolute percentage error value of the results obtained from the test data was determined as 1.6961%. Accordingly, the proposed methodology is effective for determining the distance between vehicles.

2020, 110 PAGE

**KEYWORDS:** Image Processing, Artificial Neural Networks, Distance Estimation, Stereo Camera

## ÖNSÖZ

Bu çalışmanın her aşamasında bilgi ve tecrübesinden faydalandığım saygıdeğer danışman hocam Dr. Öğr. Üyesi Bülent TURAN'a teşekkürlerimi sunarım.

Tez çalışmam boyunca benden desteklerini esirgemeyen; eşim Pınar KANYAR DURAN, annem Nuriye DURAN, babam Osman DURAN ve kardeşim Özge DURAN GERÇEKÇİOĞLU ile sevgi ve mutluluk kaynağım oğlum Kerem Mert DURAN'a sonsuz teşekkür ederim.



**10 Aralık 2020**

# İÇİNDEKİLER

Sayfa

<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>ÖNSÖZ</b> .....	<b>iii</b>
<b>İÇİNDEKİLER</b> .....	<b>iv</b>
<b>SİMGELER ve KISALTMALAR</b> .....	<b>vi</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>x</b>
<b>ÇİZELGE LİSTESİ</b> .....	<b>xii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. GENEL BİLGİLER</b> .....	<b>3</b>
<b>2.1 Görüntü İşleme</b> .....	<b>3</b>
2.1.1 Görüntü.....	4
2.1.2 İkili sayısal görüntü .....	5
2.1.3 Gri seviyeli sayısal görüntü .....	6
2.1.4 Renkli sayısal görüntü .....	8
2.1.5 Gri seviyeli sayısal görüntüye dönüşüm.....	9
2.1.6 İkili sayısal görüntüye dönüşüm.....	11
2.1.7 Kenar belirleme .....	12
<b>2.2 Yapay Sinir Ağları</b> .....	<b>14</b>
2.2.1 İnsan beyni ve biyolojik nöronlar .....	15
2.2.2 Yapay sinir hücreleri .....	16
2.2.3 Yapay sinir ağı katman yapıları.....	21
2.2.4 Geri yayılım algoritması.....	25
2.2.5 Geri beslemeli yapay sinir ağları .....	26
2.2.6 Öğretmensiz öğrenme.....	27
2.2.7 Öğretmenli öğrenme .....	28
2.2.8 Destekleyicili öğrenme .....	28
2.2.9 Hebbian öğrenme.....	29
2.2.10 Hopfield öğrenme .....	29
2.2.11 Kohonen öğrenme .....	30
2.2.12 Delta öğrenme kuralı .....	30
2.2.13 YSA performansı değerlendirme ölçütleri .....	30
2.2.14 YSA avantaj ve dezavantajları .....	32
<b>2.3 Konu ile İlgili Literatürde Yer Alan Çalışmalar</b> .....	<b>33</b>
2.3.1 Tek kamera kullanılarak yapılan çalışmalar .....	35
2.3.2 İki kamera kullanılarak yapılan çalışmalar.....	42
2.3.3 Çalışmanın literatürdeki yeri .....	54
<b>3. MATERYAL ve YÖNTEM</b> .....	<b>55</b>

<b>3.1</b>	<b>Önerilen Stereo Kamera Modeli.....</b>	<b>55</b>
3.1.1	Optik eksen eğim açısının etkisi.....	61
3.1.2	Kamera lensleri arası mesafenin etkisi .....	64
<b>3.2</b>	<b>Sistem Kurulumu .....</b>	<b>65</b>
3.2.1	Kameraların eğim açılarının ve lens aralıklarının belirlenmesi.....	66
3.2.2	Materyal.....	67
<b>3.3</b>	<b>YSA için Veri Seti Oluşturma.....</b>	<b>69</b>
3.3.1	YSA modeli için aday giriş değişkenlerinin belirlenmesi.....	69
3.3.2	Görüntü örneklerinin toplanması.....	70
3.3.3	Görüntü örneklerinden plaka merkez noktasının belirlenmesi.....	72
3.3.4	Aday giriş değişkenlerine ait veri seti değerlerinin belirlenmesi .....	75
<b>3.4</b>	<b>Yapay Sinir Ağının Modellenmesi.....</b>	<b>77</b>
<b>4.</b>	<b>BULGULAR.....</b>	<b>83</b>
<b>4.1</b>	<b>Birinci Aday Giriş Değişkenleri Kümesine Ait Bulgular .....</b>	<b>83</b>
<b>4.2</b>	<b>İkinci Aday Giriş Değişkenleri Kümesine Ait Bulgular .....</b>	<b>85</b>
<b>4.3</b>	<b>Üçüncü Aday Giriş Değişkenleri Kümesine Ait Bulgular .....</b>	<b>86</b>
<b>4.4</b>	<b>Dördüncü Aday Giriş Değişkenleri Kümesine Ait Bulgular.....</b>	<b>87</b>
<b>4.5</b>	<b>Beşinci Aday Giriş Değişkenleri Kümesine Ait Bulgular.....</b>	<b>88</b>
<b>4.6</b>	<b>Altıncı Aday Giriş Değişkenleri Kümesine Ait Bulgular.....</b>	<b>90</b>
<b>4.7</b>	<b>Yedinci Aday Giriş Değişkenleri Kümesine Ait Bulgular .....</b>	<b>91</b>
<b>4.8</b>	<b>Sekizinci Aday Giriş Değişkenleri Kümesine Ait Bulgular.....</b>	<b>92</b>
<b>4.9</b>	<b>Belirlenen YSA Modeline Ait Bulgular .....</b>	<b>93</b>
<b>5.</b>	<b>TARTIŞMA ve SONUÇ .....</b>	<b>100</b>
<b>6.</b>	<b>KAYNAKLAR .....</b>	<b>104</b>
<b>7.</b>	<b>ÖZGEÇMİŞ.....</b>	<b>110</b>

## SİMGELER ve KISALTMALAR

Simgeler	Açıklama
$\alpha$	Kameraların görüntü alma açıları
$AX_1$	A kamerası için plaka bölgesi merkez noktasının çerçeve sol kenarından uzaklığı
$AX_2$	A kamerası için plaka bölgesi merkez noktasının çerçeve sağ kenarından uzaklığı
$AY_1$	A kamerası için plaka bölgesi merkez noktasının çerçeve üst kenarından uzaklığı
$AY_2$	A kamerası için plaka bölgesi merkez noktasının çerçeve alt kenarından uzaklığı
b	Bias (eşik değeri)
$\beta$	Kameraların eğim açıları
$BX_1$	B kamerası için plaka bölgesi merkez noktasının çerçeve sol kenarından uzaklığı
$BX_2$	B kamerası için plaka bölgesi merkez noktasının çerçeve sağ kenarından uzaklığı
$BY_1$	B kamerası için plaka bölgesi merkez noktasının çerçeve üst kenarından uzaklığı
$BY_2$	B kamerası için plaka bölgesi merkez noktasının çerçeve alt kenarından uzaklığı
cm	Santimetre
C2V	Kameranın öndeki araç plaka bölgesi merkez noktasının bulunduğu yatay doğrultuya dik olan uzaklığı
$CPA_x$	Sol kamera görüntüsünde yer alan plaka bölgesi merkez noktasının görüntü koordinatlarındaki x eksenine ait değeri
$CPA_y$	Sol kamera görüntüsünde yer alan plaka bölgesi merkez noktasının görüntü koordinatlarındaki y eksenine ait değeri
$CPB_x$	Sağ kamera görüntüsünde yer alan plaka bölgesi merkez noktasının görüntü koordinatlarındaki x eksenine ait değeri

$CPB_y$	Sağ kamera görüntüsünde yer alan plaka bölgesi merkez noktasının görüntü koordinatlarındaki y eksenine ait değeri
$d$	Kamera merceğine dik olan doğrultudan kamera görüntü alanının dış sınır çizgisine olan uzaklık
$D$	Öndeki aracın sağa veya sola kayma uzaklık değerleri
$o$	Derece
$D_L$	Sol kamera ile uzaklığı tespit edilecek araç arasındaki mesafe
$D_{lens}$	Kamera lensleri arasındaki mesafe
$D_R$	Sağ kamera ile uzaklığı tespit edilecek araç arasındaki mesafe
$\Delta x$	A kamerası ile B kamerası görüntülerinde araç plakası merkez nokta lokasyonunun yatay ekseninde piksel bazındaki farkı
$\Delta y$	A kamerası ile B kamerası görüntülerinde araç plakası merkez nokta lokasyonunun dikey ekseninde piksel bazındaki farkı
$D_{V2V}$	Görüntü işlemeden yararlanılarak oluşturulan geometrik model ile hesaplanan, kamera platformu ile öndeki araç arası mesafe (İki araç arası mesafenin kalibre edilmemiş ölçüsü)
$FPA_x$	Sol kamera görüntüsünde yer alan plaka bölgesinin bitiş noktasına ait görüntü koordinatlarının x eksen değeri
$FPA_y$	Sol kamera görüntüsünde yer alan plaka bölgesinin bitiş noktasına ait görüntü koordinatlarının y eksen değeri
$FPB_x$	Sağ kamera görüntüsünde yer alan plaka bölgesinin bitiş noktasına ait görüntü koordinatlarının x eksen değeri
$FPB_y$	Sağ kamera görüntüsünde yer alan plaka bölgesinin bitiş noktasına ait görüntü koordinatlarının y eksen değeri
$HFOV_{px}$	Görüntü alanı genişliğinin piksel sayısı cinsinden ölçüsü
$I$	Ağın üretmesi istenen çıktı değeri
$K_1$	Plaka bölgesi merkez noktasının kamera görüntü alanları yatay eksenlerindeki öndeki aracın sola kayma durumunu ifade eden konumu
$K_2$	Plaka bölgesi merkez noktasının kamera görüntü alanları yatay eksenlerindeki öndeki aracın kameraların bulunduğu araç ile aynı hizada olduğu durumunu ifade eden konumu

$K_3$	Plaka bölgesi merkez noktasının kamera görüntü alanları yatay eksenlerindeki öndeki aracın sağa kayma durumunu ifade eden konumu
$L_x$	Sol kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanı genişliğinin metre cinsinden değeri
$LP_x$	Sol kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanında yer alan her bir pikselin genişliğinin milimetre cinsinden değeri
m	Metre
mm	Milimetre
s	Ağdan elde edilen çıktı değerlerinin sayısı
NET	Birleştirme fonksiyonuyla elde edilen ağın girdi değeri
$n$	Nöron sayısı
$n_i$	Giriş değişkeni sayısı
$n_o$	Çıkış değişkeni sayısı
$n_t$	Giriş ve çıkış değişkenleri sayılarının toplamı
$\Omega$	Kameralardaki görüntü alma açılarının yarısı
R	Korelasyon katsayısı
$RP_x$	Sağ kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanında yer alan her bir pikselin genişliğinin mm cinsinden değeri
$R_x$	Sağ kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanı genişliğinin metre cinsinden değeri
$SPA_x$	Sol kamera görüntüsünde yer alan plaka bölgesinin başlangıç noktasına ait görüntü koordinatlarının x eksen değeri
$SPA_y$	Sol kamera görüntüsünde yer alan plaka bölgesinin başlangıç noktasına ait görüntü koordinatlarının y eksen değeri
$SPB_x$	Sağ kamera görüntüsünde yer alan plaka bölgesinin başlangıç noktasına ait görüntü koordinatlarının x eksen değeri
$SPB_y$	Sağ kamera görüntüsünde yer alan plaka bölgesinin başlangıç noktasına ait görüntü koordinatlarının y eksen değeri
$VFOV_{px}$	Kamera görüntüsünün dikey eksenindeki piksel sayısı

W	Yapay Sinir Ağında kullanılan ağırlıklar
X	Yapay Sinir Ağı giriş deęerleri
Y	Ağın ürettięi çıktı deęeri

### **Kısaltmalar**

### **Açıklama**

AEB	Autonomous Emergency Braking
ART	Adaptif Rezonans Teorisi
B	Blue
CCD	Charge Coupled Device
CNN	Convolutional Neural Network
EURO NCAP	European New Car Assessment Programme
G	Green
GPS	Global Positioning System
HOG	Histogram of Oriented Gradients
LED	Light Emitting Diode
LIDAR	Light Detection And Ranging
MAPE	Mean Absolute Percent Error
MSE	Mean Square Error
NCC	Normalized Cross Correlation
R	Red
RADAR	Radio Detection And Ranging
RGB	Red Green Blue
RMSE	Root Mean Square Error
SGM	Semi Global Matching
TOF	Time Of Flight
VLC	Visible Light Communication
YSA	Yapay Sinir Ağları

## ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 2.1. Sayısal görüntünün oluşumu .....	4
Şekil 2.2. İkili sayısal görüntü .....	6
Şekil 2.3. Gri seviyeli sayısal görüntü .....	7
Şekil 2.4. Gri seviyeli görüntü matrisinin ilk 10x10 piksellik kısmı .....	7
Şekil 2.5. Renkli sayısal görüntünün oluşumu .....	8
Şekil 2.6. Kartezyen koordinatlarına göre RGB modeli .....	10
Şekil 2.7. RGB görüntü ve gri seviyeli görüntülere dönüşümleri .....	11
Şekil 2.8. Gri seviyeli görüntü ve ikili sayısal görüntülere dönüşümleri .....	12
Şekil 2.9. Yatay ve dikey Sobel operatörleri .....	13
Şekil 2.10. Gri seviyeli görüntü ve Sobel maskesi ile filtrelenmiş görüntüsü .....	14
Şekil 2.11. Biyolojik sinir hücresi içyapısı .....	15
Şekil 2.12. Doğrusal olmayan nöron modeli .....	16
Şekil 2.13. Sigmoid Fonksiyonu .....	19
Şekil 2.14. Hiperbolik tanjant fonksiyonu .....	19
Şekil 2.15. Doğrusal aktivasyon fonksiyonu .....	20
Şekil 2.16. Adım aktivasyon fonksiyonu .....	21
Şekil 2.17. AND, OR ve XOR problemleri için sınıflandırma .....	22
Şekil 2.18. Perceptron modeli .....	23
Şekil 2.19. Çok katmanlı ileri beslemeli YSA modeli .....	24
Şekil 2.20. Veri akışı ve hata sinyalleri .....	25
Şekil 2.21. Geri beslemeli YSA .....	27
Şekil 2.22. Öğretmensiz öğrenme blok diyagramı .....	27
Şekil 2.23. Öğretmenli öğrenme blok diyagramı .....	28
Şekil 2.24. Destekleyicili öğrenme blok diyagramı .....	29
Şekil 3.1. Hedef noktaların kameraların perspektiflerindeki konumları .....	55
Şekil 3.2. Önerilen yöntem için araç kayma miktarına göre $\Delta x$ değerleri .....	59
Şekil 3.3. Optik eksenleri paralel kamera modeli .....	60
Şekil 3.4. Paralel kameralar için $\Delta x$ değerleri değişimi .....	61
Şekil 3.5. Optik eksen eğim açılarının farklı sapma miktarlarına göre etkisi .....	63
Şekil 3.6. Farklı yatay sapma değerlerinde lensler arası mesafenin etkisi .....	64
Şekil 3.7. Sistem görünümü .....	65
Şekil 3.8. Kamera doğrultusunun dışında kalan görüntü alanı .....	66
Şekil 3.9. Görüntü alma platformu .....	68
Şekil 3.10. Görüntü alma platformunun araç üzerine yerleştirilmiş hali .....	68
Şekil 3.11. Veri seti için örnekler alma .....	71
Şekil 3.12. Stereo kamera görüntüleri .....	73
Şekil 3.13. Plaka bölgeleri belirlenmiş stereo kamera görüntüleri .....	74
Şekil 3.14. Aday giriş değişkenleri veri seti değerleri ve plaka bölgeleri .....	76
Şekil 3.15. Görüntü örneklerinin eğitim ve test verilerinin parçası olarak sınıflandırılması .....	77
Şekil 3.16. Önerilen yönteme ait YSA tasarımı akış diyagramı .....	82
Şekil 4.1. Belirlenen YSA modeline ait bilgiler .....	96
Şekil 4.2. YSA eğitimi ile elde edilen korelasyon grafiği .....	97

Şekil 4.3. Test verilerine ait YSA çıktıları ve gerçek değerler .....	99
Şekil 4.4. YSA çıktısı ve gerçek değerler arasındaki ilişki .....	99



## ÇİZELGE LİSTESİ

<b><u>Çizelge</u></b>	<b><u>Sayfa</u></b>
Çizelge 2.1. Görüntü piksel matrisi .....	5
Çizelge 3.1. Optik eksen eğim açılarına göre 9 ve 10 m'ler için $\Delta x$ değerleri .....	62
Çizelge 3.2. Belirlenen değişken kümesi grupları .....	79
Çizelge 3.3. Gizli katman nöron sayısı belirleme denklemleri .....	80
Çizelge 3.4. Aday giriş değişken kümeleri için belirlenen nöron sayıları .....	81
Çizelge 4.1. Birinci değişken kümesine ait performans değerleri .....	84
Çizelge 4.2. İkinci değişken kümesine ait performans değerleri .....	85
Çizelge 4.3. Üçüncü değişken kümesine ait performans değerleri .....	86
Çizelge 4.4. Dördüncü değişken kümesine ait performans değerleri .....	88
Çizelge 4.5. Beşinci değişken kümesine ait performans değerleri .....	89
Çizelge 4.6. Altıncı değişken kümesine ait performans değerleri .....	90
Çizelge 4.7. Yedinci değişken kümesine ait performans değerleri .....	92
Çizelge 4.8. Sekizinci değişken kümesine ait performans değerleri .....	93
Çizelge 4.9. Giriş değişkeni kümelerinin en iyi sonucu veren denemeleri .....	94
Çizelge 4.10. Belirlenen YSA modeli ile iterasyon sayısının araştırılması .....	95
Çizelge 4.11. Test verilerine ait YSA çıktı değerleri .....	98

## 1. GİRİŞ

Karayolu ulaşımının en çok dikkat edilmesi gereken konularından biri sürüş güvenliğidir. Karayolu trafiğinde yaşanan kazaların büyük bölümünün; araç sürücülerinde sürüş yorgunluğu veya dikkat dağılması sonucu çevredeki araçlara ve diğer trafik unsurlarına karşı meydana gelen dikkat eksikliğinden kaynaklandığı bilinmektedir (Zaarane ve ark., 2019). Yaşanan bu gibi durumların trafikte kazalara neden olmasının önüne geçmek için trafik hareketliliğini denetleyen sistemler, sürüş güvenliğini destekleyici araç içi sistemler, otomatik sürüş sistemleri gibi çeşitli akıllı ulaşım sistemleri geliştirilmiştir. EURO NCAP (European New Car Assessment Programme)'ın 2018 yılından itibaren üretilen araçlar için zorunlu kılmış olduğu AEB (Autonomous Emergency Braking: Otonom Acil Durum Frenlemesi) teknolojilerine olan talep artarak devam etmektedir (Lim ve ark., 2017).

Trafikte araçların öndeki araçla olan mesafelerinin güvenli sayılabilecek ölçüde olması güvenli sürüş için önemlidir. Karayolu trafiğindeki kazaların büyük bölümünü arkadan çarpmalar oluşturur (Huang ve ark., 2017). Türkiye Karayolları Trafik Yönetmeliğine göre sürücüler, önlerinde giden araçları güvenli ve gerekli bir mesafeden takip etmek zorundadırlar (Karayolları Trafik Yönetmeliği, 1997: madde 107). Aynı yönetmelikte bu mesafe, sürücüler için kendi araçlarının kilometre cinsinden saatteki hızının en az yarısı kadar metre olarak belirtilmiştir. İnsan beyni gözlerden kendisine iletilen iki görüntünün her biri üzerinde uyguladığı ön işlemlerden sonra ulaşılan görüntülerdeki nesnenin bir noktasını kullanarak o noktanın konumunu ve mesafesini belirli bir oranda tahmin edebilir (Ashoori ve Mahlouji, 2017). Ancak bu tahminde oluşabilecek olası hatalar trafikte can ve mal güvenliğini tehdit eder niteliktedir. Oluşabilecek bu türde tehlikelerin önüne geçmek adına güvenli sürüş için çeşitli teknolojiler geliştirilmiştir.

Otomasyon yani insan müdahalesinin yerini teknolojiyle bırakması; endüstri ürünlerinin gelişen teknolojiye paralel değişimleri ile birlikte maliyet, zaman ve iş gücü açısından önemli faydalar sağlamaktadır. Bu durum, gelecekte otomasyon teknolojilerinin daha yaygın olarak kullanılabileceğini göstermektedir.

Otomobillerde kullanılan otomasyon teknolojileri seyahat esnasında otomobilin çevresini algılayarak gerekli olan insan müdahalesinin yerini almayı sağlar (Emani ve ark., 2019). Bu müdahaleler bilgisayar sistemleri kullanılarak araç kontrol parçalarının otomatikleştirilmesi ile gerçekleştirilir. Bu teknolojik parçalar; önden çarpışmalar için uyarı verme, şerit tutma, uyarlanabilir hız kontrolü sağlama ve sürüşü tamamen otomatikleştirme gibi işlevleri yerine getirebilir. Taşıt otomasyonu genel olarak taşıt sürücülerinin görevlerini kısmen ya da tamamen gerçekleştirmek yoluyla yol güvenliği ve sürüş konforunu artırır. Goodall (2014)'a göre bu şekilde kazaların azaltılması ve karayolu verimliliğinin artırılması sağlanabilir. Ayrıca otomatik sürüş sistemleri içerisinde gerçekleştirilen nesne tespitine ait uygulamalar, atıkların tespiti ve engelliler için yardım gibi alanlarda kendilerine yer edinebilecek faydalar sağlar (Emani ve ark., 2019). Nesne tespiti uygulaması kullanılarak tespiti yapılan atıkların tehlikeli atık olup olmadığı ile ilgili sınıflandırmalar yapılabilir. Görme engelliler için geliştirilen uyarı sistemlerinde nesne tespiti uygulamalarıyla elde edilen öndeki nesneye ait bilgiler kullanılabilir. Son yıllarda otonom araçlar; ulaştırma, askeri ve endüstriyel alanlardaki potansiyel uygulamaları sayesinde akademik çalışmaların konusu olmuş ve endüstri üretiminde kendine yer bulmuştur (Salman ve ark., 2017).

Karayolu trafiğinde dinamik ortam içerisinde çevrenin doğru bir şekilde tanınması ve mesafe ölçümü işlemleri otonom araç sistemleri için en önemli ve zorlu görevleri oluşturur. Otomasyon teknolojileri üzerine yapılan çalışmalarda nesne uzaklığının ölçülmesinin önemi giderek artmaktadır (Hsu ve Wang, 2015). Otonom aracın güvenli bir şekilde seyahat etmesi için takip edilen araca olan emniyet mesafesini koruması gerekir. Emniyet mesafesinin korunması ön aracın mesafesinin etkili olarak tespit edilmesine bağlıdır.

Bu çalışmada amaç, karayolu trafiğinde güvenli sürüş için öndeki araçla olan mesafenin belirlenmesine yönelik yeni ve etkin bir yöntem sunmaktır. Bu amaç için arabanın üzerine yerleştirilen tavan barının uçlarına monte edilen iki kamera vasıtasıyla alınan görüntülerden yararlanılmaktadır. Kameralardan elde edilen görüntüler bir Yapay Sinir Ağı (YSA) modeline ait veri setinin oluşturulmasında kullanılmaktadır. Farklı girdi kümeleri ve farklı YSA modelleri ile yapılan denemelerdeki en iyi mesafe tahmini performans değerlerine ulaşan YSA modelinin belirlenmesi hedeflenmektedir.

## **2. GENEL BİLGİLER**

Tez çalışmasında öncelikle stereo kameradan alınan görüntüler üzerinde öndeki aracın plaka bölgesinin merkez noktasının piksel koordinatları tespit edilmiştir. Daha sonra belirlenen piksel koordinatlarından yararlanılarak bir YSA modeli oluşturulmuştur. YSA modeli öndeki aracın hangi uzaklıkta olduğuna dair bir sonuç üretmektedir. Tez çalışması bazı görüntü işleme ve YSA uygulamalarını içermektedir. Bu bölümde görüntü işleme ve YSA konularının tez çalışmasında yer alan uygulamalarda kullanılan kısımlarıyla ilgili bilgilendirmeler yapılmıştır. Bu bölümün son kısmında ise tez çalışmasıyla ilgili literatürde daha önce yapılmış çalışmalar hakkında bilgi verilmiştir.

### **2.1 Görüntü İşleme**

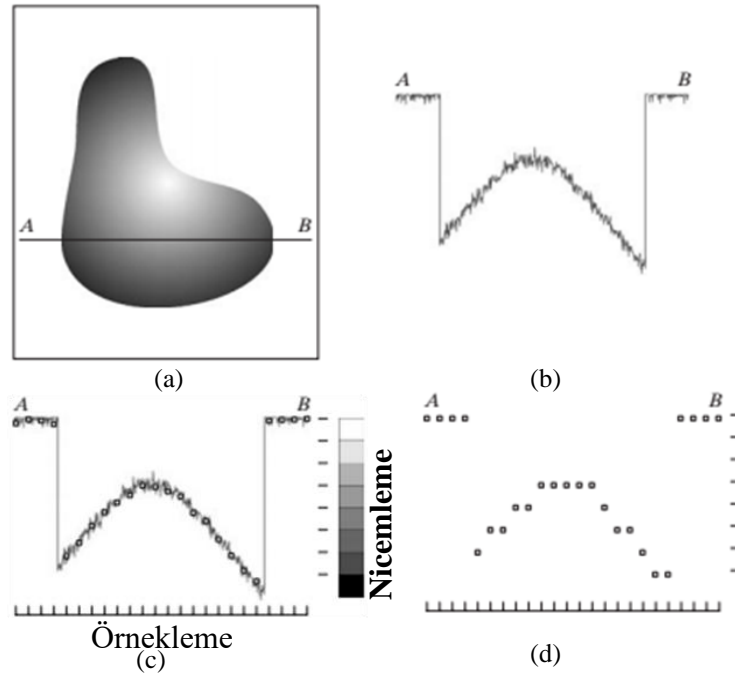
Gerçek hayattaki analog görüntülerin dönüştürülmesiyle elde edilen dijital görüntü verilerini bilgisayar yazılımları vasıtasıyla istenilen özelliklere sahip dijital görüntü verilerine dönüştürme işlemleri görüntü işleme olarak adlandırılır. Görüntü işleme kaydedilmiş dijital görüntü verilerinin iyileştirilmesi veya amacına uygun olarak resmin istenilen bir bölgesinin belirli özelliklerinin çıkarılması için kullanılır (Yavuz, 2008).

Gerçek hayattaki analog görüntülerin bilgisayar ortamında kullanılabilmesi için dijital verilere çevrilmesi gerekir. Analog görüntüler dijitalle çevrildiklerinde resim verilerinde netliğin bozulmasına yol açan gürültü barındırabilirler veya görüntü kaybı oluşabilir (Akar, 2009). Bu hataların giderilmesi için keskinleştirme, kontrast artırma ve gürültü azaltma gibi görüntü işleme tekniklerinden faydalanılabilir (Gonzales ve Woods, 2008). Eğer resim üzerindeki belirli bir alan üzerinde çalışma yapılması gerekiyorsa, resim içerisinde yer alan bir nesneye veya bir bölgeye ait alanların belirlenmesi gerekebilir. Bu işlem için görüntü işlemeden yararlanır. Sadece belirlenen kısımlar üzerinde görüntü işleme algoritmalarının işletilmesi yazılım karmaşıklığını azaltıcı bir etki oluşturur.

## 2.1.1 Görüntü

Analog görüntü sinyallerinin bilgisayarda işlenmek üzere dijitale çevrilmeleri konumsal değerleri ve renk bilgileri için gerçekleştirilir. Renk bilgisine genlik adı da verilir. Konumsal değerler yani görüntü koordinatları için yapılan sayısallaştırma işlemi örnekleme olarak adlandırılırken, renk bilgisi yani genlikte yapılan sayısallaştırma işlemi nicemleme veya kuantalama olarak adlandırılır.

Şekil 2.1’de örnekleme ve nicemleme ile sürekli görüntü sinyalinin ayırık sinyallere dönüştürülmesi gösterilmiştir. Şekil 2.1(a) sayısal sinyale dönüştürülecek olan görüntüyü temsil etmektedir. Şekil 2.1(b)’deki sürekli fonksiyon Şekil 2.1(a)’daki görüntünün AB doğrusu boyunca genlik değerlerini gösterir. Bu sürekli fonksiyondan Şekil 2.1(c)’de AB doğrusu boyunca eşit aralıklarla örnekler alınarak örnekleme yapılmıştır. Örnekler sürekli fonksiyon üzerinde işaretlenmiştir. Dikeyde ise işaretlenen örnekler için nicemleme yapılarak genlik değerleri çizgilerle gösterilmiştir. Şekil 2.1. (d)’de örnekleme ve nicemleme sonucu sayısallaştırılmış ayırık değerler görülmektedir.



Şekil 2.1. Sayısal görüntünün oluşumu (Gonzales ve Woods, 2008). (a: Sürekli zaman görüntüsü, b: A'dan B'ye tarama çizgisine ait sürekli görüntü fonksiyonu, c: Örnekleme ve nicemleme, d: Sayısal tarama çizgisi)

Sayısal bir görüntü sürekli bir görüntü fonksiyonundan yatayda ve dikeyde eşit aralıklarla alınan örneklerle meydana getirilir. Analog görüntü; yatayda M ve dikeyde N örneklemeyle, M satır ve N sütundan oluşan bir dijital görüntü matrisine dönüşmüş olur. Bu dönüşüm sırasında görüntüde veri kaybı gerçekleşir.

Görüntü iki değişkenli bir fonksiyon olarak,  $f(x,y)$  olarak ifade edilebilir. Burada görüntü koordinatlarını belirten her  $x,y$  çifti için  $f(x,y)$ ; görüntünün yoğunluğu veya gri seviyesi olarak adlandırılır.

Bir görüntü piksel adı verilen görüntünün temel elemanlarının toplamıdır. Pikseller bir araya gelerek M satır ve N sütundan oluşan  $M \times N$  boyutlarında bir piksel matrisi oluştururlar. Çizelge 2.1’de görüntü piksel matrisine ait gösterim bulunmaktadır.


Çizelge 2.1. Görüntü piksel matrisi

		Sütunlar →						
		1	2	3	4	5	...	N
Satırlar →	1	$f(0,0)$	$f(0,1)$	$f(0,2)$	$f(0,3)$	$f(0,4)$	...	$f(0,N-1)$
	2	$f(1,0)$	$f(1,1)$	$f(1,2)$	$f(1,3)$	$f(1,4)$	...	$f(1, N-1)$
	3	$f(2,0)$	$f(2,1)$	$f(2,2)$	$f(2,3)$	$f(2,4)$	...	$f(2,N-1)$
	4	$f(3,0)$	$f(3,1)$	$f(3,2)$	$f(3,3)$	$f(3,4)$	...	$f(3,N-1)$
	5	$f(4,0)$	$f(4,1)$	$f(4,2)$	$f(4,3)$	$f(4,4)$	...	$f(4,N-1)$
	...	...	...	...	...	...	...	...
M	$f(M-1,0)$	$f(M-1,1)$	$f(M-1,2)$	$f(M-1,3)$	$f(M-1,4)$	...	$f(M-1,N-1)$	

Sayısal görüntüler sahip oldukları genlik değerlerinin niteliğine göre; ikili sayısal görüntü, gri seviyeli sayısal görüntü ve renkli sayısal görüntü olmak üzere üçe ayrılırlar.

### 2.1.2 İkili sayısal görüntü

İkili görüntüde imge siyah ve beyaz pikseller dışında başka bir renk barındırmaz. Dolayısıyla görüntü piksel matrisinde, genlik değerleri sıfır ve birlerden oluşur. Şekil 2.2’de ikili sayısal görüntüye ait bir gösterim sunulmuştur.



Şekil 2.2. İkili sayısal görüntü

Şekil 2.2’de görüntünün köşe noktalarına ait koordinat bilgileri ve genlik değerleri görülmektedir. Bu değerler incelendiğinde görüntünün x eksenini boyunca 1071 piksel uzunluğunda ve y eksenini boyunca 587 piksel yüksekliğinde olduğu görülmektedir. Dolayısıyla görüntüde toplam 1071x587 piksel bulunur. Bu değer görüntü çözünürlüğü olarak adlandırılır. Görüntünün işaretlenen piksellerindeki index ile gösterilen genlik değerlerinin 0 veya 1 olduğu görülmektedir.

### 2.1.3 Gri seviyeli sayısal görüntü

Gri seviyeli görüntüde renk seviyeleri ikili resimden farklı olarak parlaklık seviyelerine göre grinin farklı tonlarını da içerir. Piksellerin genlik değerleri 0 ile 255 arasındadır. Parlak beyaz renk 255 değerini alırken koyu siyah renk 0 değerini alır (Bora, 2009). Bu tam tersi de olabilir (Bakkaloğlu, 2011). Aradaki renkler ise parlaklık şiddetine göre 0 ile 255 arasındaki gri seviyelerini ifade eder. Şekil 2.3’te gri seviyeli sayısal görüntüye ait gösterim bulunmaktadır.



Şekil 2.3. Gri seviyeli sayısal görüntü

Şekil 2.3'te köşe noktalarında işaretlenen piksellere ait koordinat bilgileri ve gri seviye genlik değerleri bilgileri görülmektedir. Şekil 2.2 ile aynı koordinat bilgilerine sahip iken gri seviye index değerlerinin değiştiği görülmektedir. Piksellerdeki R (Red), G (Green) ve B (Blue) değerlerinin birbirine eşit olduğu görülmektedir. Gri seviye rengi; R, G ve B bileşenlerinin genlik değerlerinin eşit olduğu noktadaki rengidir.

Gri seviyeli görüntü matrisi piksellere ait 0 ile 255 arasındaki genlik değerlerinin bir araya getirilmesiyle oluşur. Şekil 2.3 için bu matris 587 satır ve 1071 sütundan oluşur. Şekil 2.3'teki görüntüye ait matrisin ilk on sütun ve ilk on satırdan oluşan kısmı Şekil 2.4'te gösterilmiştir.

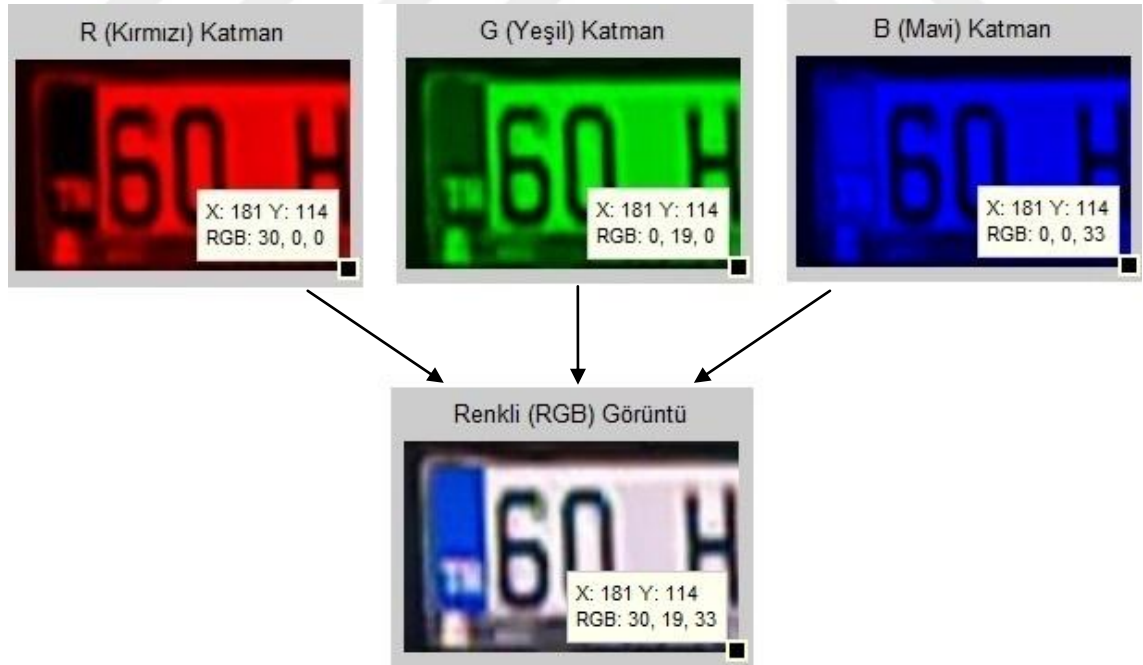
cut_ig <587x1071 uint8>										
	1	2	3	4	5	6	7	8	9	10
1	119	118	118	119	119	120	119	119	119	118
2	119	118	118	119	119	120	119	119	119	118
3	119	118	118	119	119	120	119	119	119	118
4	119	118	118	119	119	120	119	119	119	118
5	119	119	119	119	119	119	119	119	119	118
6	119	119	119	119	119	119	119	119	119	118
7	119	119	119	119	119	119	119	119	119	118
8	119	119	119	119	119	119	119	119	119	118
9	119	119	119	119	119	119	119	119	119	118
10	119	119	119	119	119	119	119	119	119	118

Şekil 2.4. Gri seviyeli görüntü matrisinin ilk 10x10 piksellik kısmı

#### 2.1.4 Renkli sayısal görüntü

RGB (Red Green Blue) görüntüde; R, G ve B genlik değerleri bilgisi görüntüyü oluşturan her pikselde mevcuttur. Genlik değerleri üç renk için de 0 ile 255 arasında değerler alır. Renkli görüntü R, G ve B için oluşturulan üç matrisin bir araya ve üst üste getirilmesiyle oluşturulur.

Şekil 2.5'te renkli bir sayısal imge ve bu imgenin R, G ve B katmanlarına ait görüntüler yer almaktadır. RGB görüntü renk kodu değerleri 0 ile 255 arasında olan R, G ve B katmanlarına ait matrislerin bir araya getirilmesiyle oluşur. Bu imgelede işaretlenen en sonuncu piksellerde; o piksellere ait koordinat bilgileri ve sırasıyla R, G ve B genlik değerleri görülmektedir. RGB görüntüye ait pikselde renk kodlarının 30, 19, 33 olmak üzere üç değerden oluştuğu görülmektedir. Birinci değer R katmanından, ikinci değer G katmanından ve üçüncü kısımdaki değer ise B katmanından geldiği görülmektedir. Katmanların RGB kodlarına ait diğer değerleri sıfırdır. Dolayısıyla görüntü piksel renk değerlerinin üç katmanın birleşimiyle oluştuğu görülmektedir.



Şekil 2.5. Renkli sayısal görüntünün oluşumu

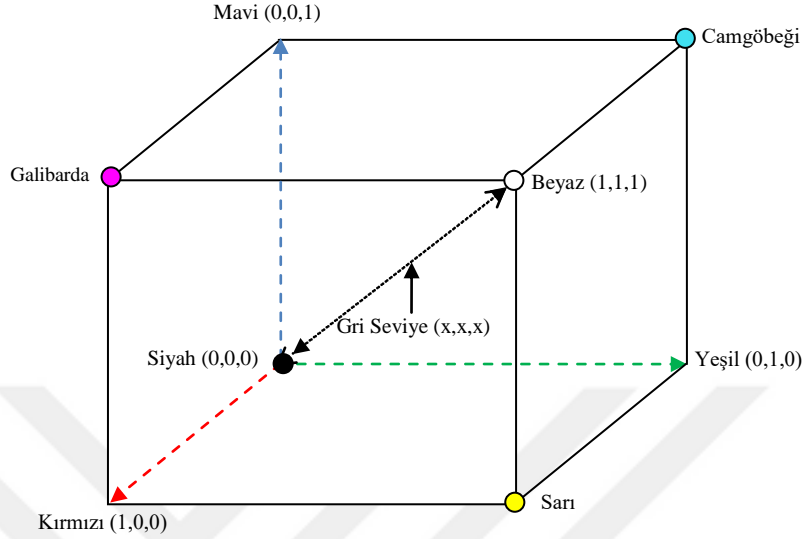
RGB renk modeline göre her pikselde, piksel derinliđi olarak adlandırılan bit sayısı kadar veri bulunur. R, G ve B katman bileşenleri sekizer bitlik görüntüye sahiptir. Dolayısıyla RGB modeli ile belirlenen renkli bir görüntüdeki her bir piksel 24 bit renk derinliđine sahiptir. Piksel derinliđi 8 bit olan bir katman bileşeni  $2^8 = 256$  adet renk barındırır. RGB modelindeki bir piksel için renk sayısı  $(2^8)^3 = 16\ 777\ 216$  'dır. Her pikseli üzerinde 24 bitlik veri barındıran RGB renk modeline sahip renkli bir görüntünün işlenmesi bilgisayar performansı açısından dezavantajlıdır ve büyük zaman kaybına neden olur. Piksel derinliđi 8 bitten oluşan gri seviyeli sayısal görüntülerle çalışmak ise RGB modeline göre avantajlıdır. Sadece 0 ve 1 değerleriyle işlem yapılan ikili sayısal görüntüler ise oldukça kısa süreli çalışma zamanı sağlarlar. Bu avantajlardan faydalanmak için RGB modeline sahip renkli sayısal görüntüler; gri seviyeli sayısal görüntülere veya ikili sayısal görüntülere dönüştürülebilirler. Ancak bu dönüşümler sırasında görüntülere ait bazı detay bilgilerinde kayıplar olmaktadır. Gerçekleştirilecek işleme göre gri seviyeli sayısal görüntü veya ikili sayısal görüntü dönüşümlerinden hangisinin yapılacağı belirlenebilir.

### **2.1.5 Gri seviyeli sayısal görüntüye dönüşüm**

RGB modelinde renkler; kırmızı, yeşil ve mavi renklerinin farklı tonlarda birleşimiyle meydana gelir. Kırmızı, yeşil ve mavi renkler; 0 ile 255 arasındaki renk kodları ile ifade edilir. 0 rengin en açık tonudur ve renkler; 255'e kadar rengin en koyu tonuna doğru sıralanır. Bu model kartezyen koordinat sistemi ile ifade edilebilir.

Kartezyen koordinat sisteminde görüntüye ait renk değerlerinin R, G ve B renk kodu bileşenlerinden oluşan uzaysal üç boyutlu gösterimi bulunur. Orijin noktası (0,0,0) olarak ifade edilir. R, G ve B eksen değerleri 0 olduğunda siyah renk değeri meydana gelir dolayısıyla orijin noktası siyah renktir. R, G ve B eksen değerlerinin hepsinin 1 olduğu durumda ise beyaz renk değeri ifade edilmiş olur. Gri seviyeli görüntüye ait değerler kartezyen koordinat sisteminde siyah noktadan beyaz noktaya doğru çizilmiş bir doğru ile gösterilir. Bu doğruya ait R, G ve B eksen değerleri (x,x,x) olarak ifade edilebilir ve birbirine eşittir.

Şekil 2.6’da kartezyen koordinat sistemine ait bir gösterim bulunmaktadır. Şekilde 0 ile 255 arasındaki renk değerleri [0,1] aralığında normalize edilmiştir.



Şekil 2.6. Kartezyen koordinatlarına göre RGB modeli

Renkli bir sayısal görüntünün gri seviyeli sayısal görüntüye dönüştürülmesi kartezyen koordinat sistemine göre şu şekilde ifade edilebilir: Renkli sayısal görüntü piksellerine ait kartezyen koordinat sistemi gösteriminde yer alan RGB koordinat değerleri, gri seviye doğrusunda bulunan değerlerden biri ile değiştirilir. Bu renkli bir sayısal görüntüde yer alan piksellerdeki farklı RGB renk kodu değerlerinin hepsinin ortak bir değerde buluşturulması anlamına gelir. Örneğin; renkli bir sayısal görüntüye ait olan bir pikselin sahip olduğu (155,56,25) RGB koordinat değerleri, kartezyen koordinat sisteminde gri seviye doğrusuna ait değildir. Gri seviye doğrusunda yer alan RGB koordinat değerleri birbirine eşit olduklarından renkli sayısal görüntüdeki piksele ait olan RGB koordinat değerlerinin birbirlerine eşitlenmesi gerekir. Bu eşitliğin sağlanması için iki yöntem kullanılabilir:


Birinci yöntemde; renkli sayısal görüntüdeki RGB kanallarına ait üç değerlerin ortalamalarının alınarak gri seviye kanal değerlerinin belirlenmesi sağlanır. Bu değerler Eşitlik 2.1. örneğinde olduğu gibi hesaplanır.

$$I=(R+G+B)/3 \quad (2.1)$$

İkinci yöntemde ise gri seviye kanal değerleri, renkli sayısal görüntüdeki RGB kanallarına ait üç değer belirlenmiş oranlarda dâhil edilmesiyle hesaplanır. İnsan gözünün kırmızı, yeşil ve mavi renklere olan duyarlılıkları farklılık gösterir. Hangi renk kanalından hangi oranda kullanılacağı, insan gözünün renklere olan duyarlılığı dikkate alınarak belirlenen gri seviye resim genlik değerleri ile oluşturulan gri seviyeli sayısal görüntüler en iyi sonucu verir. Eşitlik 2.2’de hesaplamaya ait formül bulunmaktadır.

$$I=0.299R+0.587G+0.114B \quad (2.2)$$

Şekil 2.7’de sırasıyla; renkli bir görüntü, RGB kanallarına ait değerlerin ortalamaları alınarak dönüştürülmüş gri seviyeli görüntü ve RGB kanallarına ait değerlerin insan gözünün renklere olan duyarlılığına göre belirlenmiş oranları kullanılarak dönüştürülmüş gri seviyeli görüntü bulunmaktadır.



Şekil 2.7. RGB görüntü ve gri seviyeli görüntülere dönüşümleri. (a: RGB sayısal görüntü, b:  $(R+G+B)/3$  formülü ile dönüştürülmüş gri seviyeli görüntü, c:  $0.299R+0.587G+0.114B$  formülü ile dönüştürülmüş gri seviyeli görüntü)

### 2.1.6 İkili sayısal görüntüye dönüşüm


Gri seviyeli sayısal bir görüntü ikili sayısal bir görüntüye çevrilirken gri seviye piksellerin sahip olduğu 0 ile 255 arasındaki genlik değerleri belirlenen bir eşik değerine göre 0 veya 1’e dönüştürülür. Eşik değerinin altında kalan değerler 0 yani siyah; diğer değerler 1 yani beyaz olarak belirlenir.

Eşik değerinin belirlenmesiyle ilgili birçok yöntem bulunur. En basit eşik belirleme yöntemlerinden bir tanesi belirlenen rastgele bir eşik değerine göre ikili görüntüye dönüştürmedir. Ancak bu yöntem değişken ışığa sahip dış ortamlarda çekilen görüntülerde meydana gelebilecek farklı parlaklık seviyeleri için uygun eşik değerinin

belirlenmesi için yoğun uğraşı gerektirebilir. Uygun eşik değeri kullanılmadığı takdirde dönüştürülen ikili resim, kalite ve netlik açısından uygun sonucu vermeyebilir (Otsu, 1979).

En çok kullanılan eşik belirleme yöntemlerinden bir tanesi Otsu eşikleme yöntemidir. Otsu (1979)'nun geliştirmiş olduğu eşikleme algoritma yöntemi ile farklı parlaklıklardaki görüntüler için uygun eşik değeri bulunabilir. Bu yöntemde gri seviyeli görüntü arka plan ve nesne olarak belirlenir. Bunun için öncelikle görüntünün histogramı oluşturulur. Histogram çıkarma gri seviye görüntüler için genlik değerlerinin dağılımını gösterir. Daha sonra ise otsu algoritması ile uygun eşik değeri belirlenir.

Şekil 2.8'de sırasıyla gri seviyeli bir sayısal görüntü ile bu görüntünün; otsu eşikleme yöntemi ile dönüştürülmüş ikili seviye görüntüsü ve eşik değeri 127 alınarak dönüştürülmüş ikili seviye görüntüsü bulunmaktadır. Otsu algoritması ile belirlenen eşik değerine göre dönüştürülen ikili görüntünün sabit 127 eşik değeri kullanılarak dönüştürülen ikili görüntüye oranla daha iyi sonuç verdiği görülmektedir.



Şekil 2.8. Gri seviyeli görüntü ve ikili sayısal görüntülere dönüşümleri (a: Gri seviyeli görüntü, b: Otsu yöntemi ile dönüştürülmüş ikili sayısal görüntü, c: Eşik değeri 127 belirlenerek dönüştürülmüş ikili sayısal görüntü)

### 2.1.7 Kenar belirleme

Bir görüntü arka plan görüntüsü ve ön plan görüntüsü olmak üzere iki kısma ayrılabilir. Ön plan görüntüsü görüntü içerisinde bulunan nesnelere kapsarken arka plan nesne dışında geri kalan bölgenin görüntüsüdür. Örneğin; içerisinde araba resmi bulunan bir görüntüde arabanın yer aldığı alan ön plan görüntüsü olarak değerlendirilirken araba

nesnesinin dışında kalan görüntü alanı arka plan görüntüsü olarak kabul edilir. Sadece arabadan oluşan bir görüntüde ise yapılacak işleme bağlı olarak plaka alanına ait görüntü bölgesi ön plan görüntüsü olarak değerlendirilebilirken plakanın dışında kalan görüntü bölgesi arka plan görüntüsü olarak kabul edilebilir.

Ön plan görüntüsü olarak belirlenen bir cisim içerisindeki piksellerin değerleri genellikle birbirine yakındır. Ön plan ile arka plan piksel değerleri arasında ise belirgin oranda farklılıklar bulunur. Bu farklılıkların oluşmaya başladığı bölgeler ön plan görüntüsü olarak belirlenmiş olan cismin kenar bölgeleri olarak adlandırılır. Kenar bölgesi, ön plan ve arka plan bölgeleri arasında bulunan birbirine bağlı noktalar bütünüdür (Gonzales ve Woods, 2008).

Kenar belirleme ile ilgili birçok yöntem bulunmaktadır. Kenar belirlemede kullanılan yöntem hedef nesnenin arka plan görüntüsünden ayrılmasında önemli etkiye sahiptir. Jähne (2005) tarafından bildirildiğine göre; kenar belirleme yöntemi, sabit gri seviye genlik değerlerini bastırmalı ve farklılıklara duyarlı olmalıdır. Piksel değerlerindeki ani değişimlere dayalı gradyan temelli kenar belirleme yöntemleri bulunmaktadır. Bu yöntemler birinci derece türev hesaplamasına dayanır. Kenar belirleme, gradyanın değişik doğrultular için hesaplanarak birleştirilmesi tekniği ile gerçekleştirilir. Sobel, Roberts ve Prewitt operatörleri bu tür kenar belirleme yöntemlerine örnek olarak gösterilebilir. Bir diğer yöntemde ise; görüntünün ikinci türevi alınarak sıfır geçişleri üzerinden kenar bölgeleri tespit edilmektedir. LoG filtresi ile kenar belirleme bu yöntemde örnek gösterilebilir. LoG filtresi yöntemi sırasıyla Laplace ve Gauss filtrelerinin uygulanması tekniğine dayanır (Şenel, 2007).

En çok bilinen kenar belirleme yöntemlerinden birisi Sobel kenar belirleme yöntemidir. Sobel kenar belirleme operatörü, kenarların beyaz, arka planın siyah renkte olmasını sağlar. Şekil 2.9'da Sobel operatörüne ait yatay ve dikey maskeler bulunmaktadır.


$$G_x = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad G_y = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix}$$

(a) (b)

Şekil 2.9. Yatay (a) ve dikey (b) Sobel operatörleri

Şekil 2.9’da bulunan  $G_x$  maskesi yatay olarak,  $G_y$  maskesi ise dikey olarak görüntü üzerindeki tüm piksellerde gezdirilir. Böylelikle tüm pikseller için, maske ortasına gelen piksellerin  $G_x$  ve  $G_y$  değerleri hesaplanır. Daha sonra Eşitlik 2.3 kullanılarak piksellerin yeni değeri bulunmuş olur. Şekil 2.10’da Sobel operatörü kullanılarak kenar belirleme işlemine ait görüntü bulunmaktadır.

$$G = \sqrt{G_x^2 + G_y^2} \quad (2.3)$$



Şekil 2.10. Gri seviyeli görüntü (solda) ve Sobel maskesi ile filtrelenmiş görüntüsü (sağda)

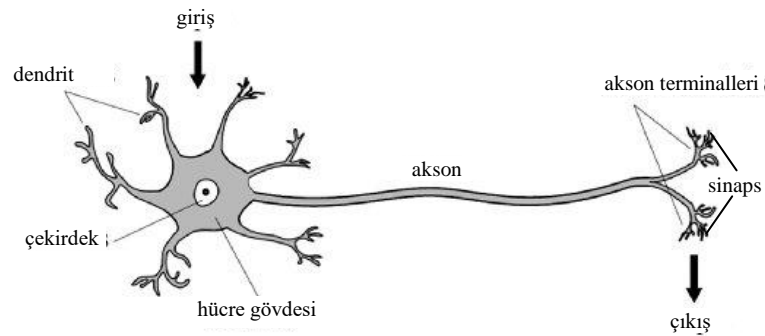
## 2.2 Yapay Sinir Ağları

Yapay sinir ağları (YSA); insan beyninde bulunan biyolojik sinir hücrelerinin içyapısı ve çalışma prensiplerinden esinlenilerek tasarlanmış, verilen bilgiyi kullanarak eğitilip öğrenmeleri için programlanabilen karar verme yapılarıdır (Graupe, 2013). Bilgisayarda oluşturulmuş YSA modelinde örnek veriler üzerinden eğitim gerçekleştirilir. Daha sonra YSA modeli hiç karşılaşmadığı veriler ile teste tabi tutularak bir çözüm ya da sonuç üretmesi beklenir (Sönmez Çakır, 2019).

## 2.2.1 İnsan beyni ve biyolojik nöronlar

İnsan beyninin yapısı ve çalışma fonksiyonları ile ilgili çok sayıda çalışma olmasına karşın insan beyninin çalışma sistemi hakkında bilgiler oldukça sınırlıdır. Buna karşın, bu alanda yapılan çalışmalarda elde edilen sınırlı bilgiler insan beyninin öğrenme mantığı örnek alınarak oluşturulan YSA modelinin ortaya çıkması için yeterli olmuştur. İnsan beyninin yapısı ile ilgili yapılan çalışmalar beyindeki farklı bölümlerin farklı işlevler gerçekleştirdiğini ortaya koymuştur (Aydemir ve Kayıkçıoğlu, 2009). Dış ortamdan reseptörler vasıtasıyla algılanan sinyaller beyinde bulunan sinir ağlarında işlenerek hangi eylemin uygulanacağını belirleyen karar sinyallerine dönüştürülür. Bu sinyaller beyin dışına aktararak komut ve eylemleri oluşturur.

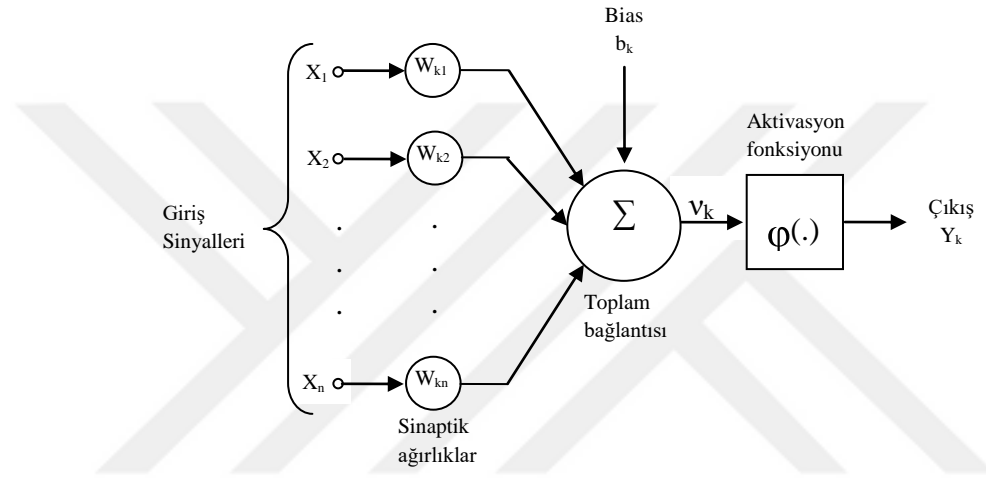
Sinir sisteminin merkezi olan insan beyninin en temel işlem birimi nöron olarak adlandırılan sinir hücreleridir (Sönmez Çakır, 2019). Farklı şekil ve büyüklüklerde olan nöronlar birbirleriyle bağlantılıdır (Ersoy ve Karal, 2012). Nöronlarda yer alan soma adı verilen hücre gövdesi içerisinde çekirdek yer alır. Çekirdek, sinir hücrelerinin gereksinim duyduğu maddeleri barındıran plazma ve kalıtsal nitelikleri ihtiva eder. Hücre gövdesinin dendrit denilen kısa uzantıları ve akson denilen uzun uzantıları bulunur. Aksonlar uçlarında bulunan sinaps adı verilen iletili bağlantı noktaları aracılığıyla diğer nöron veya nöron olmayan hücelere hücre gövdesinin ürettiği bilgileri iletirler. Hücre gövdesinin kısa olan diğer uzantıları dendritler ise diğer nöronlardan gelen uyarıları algılayarak bu uyarıların hücre gövdesine aktarılmasına yardımcı olur (Yazıcı ve ark., 2007). Biyolojik sinir hücrelerinin içyapısı Şekil 2.11’de görülmektedir.



Şekil 2.11. Biyolojik sinir hücresi içyapısı (Neves ve ark., 2018)

## 2.2.2 Yapay sinir hücreleri

Bir YSA hücresi beş ana bölümden oluşur. Bu bölümler; girdiler, birleştirme fonksiyonu, ağırlıklar, aktivasyon fonksiyonu ve çıkışlardır. Biyolojik sinir hücreleri ile karşılaştırıldığında birleştirme fonksiyonu dendritlere, ağırlıklar sinapslara, aktivasyon fonksiyonu çekirdeğe, çıktılar aksonlara karşılık gelir (Kaftan, 2010). Yapay sinir hücrelerine ait model Şekil 2.12’de gösterilmiştir.



Şekil 2.12. Doğrusal olmayan nöron modeli (Haykin, 1999)

### Giriş sinyalleri

Giriş sinyalleri dışarıdan YSA’ya işlem yapılmak üzere gelen verilerdir. Girdiler diğer sinir ağı hücrelerinin çıktıları olabileceği gibi direkt dış ortamdan gelen verilerden de oluşabilir (Öztemel, 2003). Girdiler YSA hücresinde öğrenme veya test verisi olarak kullanılabilir.

### Ağırlıklar

Ağırlıklar; giriş verilerinin çıkış değeri üzerindeki etkisini belirler. Her giriş verisi çıktı üzerinde aynı etkiye sahip değildir. Eğitim verileri ilk defa ağına sunulduğunda her giriş verisi rastgele bir ağırlık değeri ile çarpılarak sonraki işlem basamağına aktarılır. Ağıın üretmiş olduğu çıktı ile olması gereken çıktı değeri karşılaştırılır. Eğer ağıın üretmiş olduğu çıktı değeri olması gereken çıktıya göre kabul edilebilir hata oranına sahip değilse

YSA başa dönerek giriş verilerinin ağırlık değerlerini değiştirir. Bu işlem uygun sonuç değerine ulaşana kadar devam eder (Sönmez Çakır, 2019). Ağırlıklar pozitif değerler alabileceği gibi negatif değerler de alabilir (Caner ve Akarslan, 2009). Ağırlığın sıfır değerine sahip olması ağırlıkla ilişkili giriş verisinin sonuç üzerinde hiç etkisinin olmadığını gösterir (Öztemel, 2003).

### Eşik değeri

Bias ile ifade edilen eşik değeri; biyolojik sinir hücrelerinin yüzeylerinde bulunan gerilim farkı değerlerinin bir benzerini yapay sinir hücrelerine uygulamak için kullanılır (Göçerler, 2015). Eşik değeri, YSA çıktı değerinin sıfır olmasını engeller (Kaftan, 2010). Eşik değeri birleştirme fonksiyonunda hesaplanan değere ilave edilerek çıkan sonuç aktivasyon fonksiyonuna giriş parametresi olarak verilir. Eşik değeri ile toplama, aktivasyon fonksiyonunun çıktı uzayının yatayda kaydırılmasına neden olur. Eşik değeri sabit olarak belirlenen bir giriş değeri değil, ağırlık eğitimi esnasında hesaplanan bir değerdir (Çamaşırıcıoğlu, 2007).

### Birleştirme fonksiyonu

Birleştirme fonksiyonu; giriş değerlerinin ağırlıklar ile çarpılarak işlem gördüğü yerdir. Bu işlem genellikle girdilerin ağırlık değerleriyle çarpılarak toplanması şeklinde olur. Ancak toplama yerine farklı hesaplama yöntemleri de kullanılabilir (Sönmez Çakır, 2019). Toplama yöntemi ile gerçekleştirilen fonksiyona ait formül Eşitlik 2.4'te gösterilmiştir. Formülde yer alan NET ifadesi ağ yapısının toplam girdi değerlerini ifade eder. X değerleri ağa gelen giriş değerlerini ifade ederken; W; bu girdilere ait ağırlıkların sembolüdür. Giriş değerlerinin ağırlıklarıyla çarpımlarının toplanarak, b ile ifade edilen eşik değeri ile toplanmasıyla NET girdi değeri hesaplanmıştır.

$$NET = \sum_{i=1}^n X_i \cdot W_i + b \quad (2.4)$$


### Aktivasyon fonksiyonu

Aktivasyon fonksiyon birleştirme fonksiyonu ile elde edilen NET girdi değerini parametre olarak kullanarak ağıın çıktı değerini verir (Öztemel, 2003). Birleştirme fonksiyonu ile elde edilen değerler çok büyük değerler olabilir. Aktivasyon fonksiyonu aynı zamanda bu büyük değerleri normalize eder. YSA eğitimi aşamasında hatalı çıktı değerinin düzeltilmesi için geri yayılım algoritmalarını kullanılır. Bu algoritmalar hesaplamalarda aktivasyon fonksiyonunun türeviyle işlem yaptığı için aktivasyon fonksiyonunun, türevi hesaplanabilir bir fonksiyon olması gerekir (Yıldız, 2009). YSA, doğrusal ve doğrusal olmayan sistemlerde sonuç verebilir. Aktivasyon fonksiyonlarının doğrusal, doğrusal olmayan ya da her iki sistem için de etkin sonuç veren çeşitleri vardır. Bunlardan hangi aktivasyon fonksiyonu çeşidinin kullanılacağı problemin niteliğine göre karar verilir. Aktivasyon fonksiyonu olarak farklı fonksiyon tipleri seçilebilir. Sigmoid, hiperbolik tanjant, doğrusal, doğrusal pozitif, adım, rampa, gaussian, satlin, satlins, hardlim ve hardlims fonksiyonları kullanılan aktivasyon fonksiyonlarından bazılarıdır. Bu aktivasyon fonksiyonları arasında en yaygın olarak kullanılanları ise; sigmoid, hiperbolik tanjant, doğrusal ve adım fonksiyonlarıdır (Kaftan, 2010).

#### *Sigmoid (Logsig) Fonksiyonu*

YSA'da en fazla tercih edilen aktivasyon fonksiyonlarından biri sigmoid fonksiyonudur (Demuth ve Beale, 2004; Irmakçı, 2008). Sigmoid fonksiyonu NET çıktı değerini 0 ile 1 arasında bir değer olarak verir. Bu fonksiyon doğrusal ve doğrusal olmayan sistemlerin her ikisi için de uygun sonuçlar verebilir (Öztemel, 2003). Sigmoid fonksiyona ait; grafiksel gösterim Şekil 2.13'te, denklem Eşitlik 2.5'te görülmektedir.

$$f(\vartheta) = \frac{1}{1 + e^{-\vartheta}} \quad (2.5)$$




Şekil 2.13. Sigmoid Fonksiyonu

*Hiperbolik tanjant (Tansig) Fonksiyonu*

Hiperbolik tanjant fonksiyonu kullanılırken öncelikle giriş değerleri  $[-1,1]$  aralığına uyarlanır (Vogl ve ark., 1988). Çıkış değerleri de  $[-1,1]$  aralığında olur. Bu fonksiyon, çıkış değerlerinin  $[-1,1]$  aralığında olması istenen YSA uygulamaları için tercih edilir (Haykin, 1999). YSA uygulamalarında en fazla tercih edilen aktivasyon fonksiyonlarından biri de Hiperbolik tanjant fonksiyonudur (Demuth ve Beale, 2004). Hiperbolik tanjant fonksiyonuna ait; denklem Eşitlik 2.6'da, grafiksel gösterim Şekil 2.14'te görülmektedir.

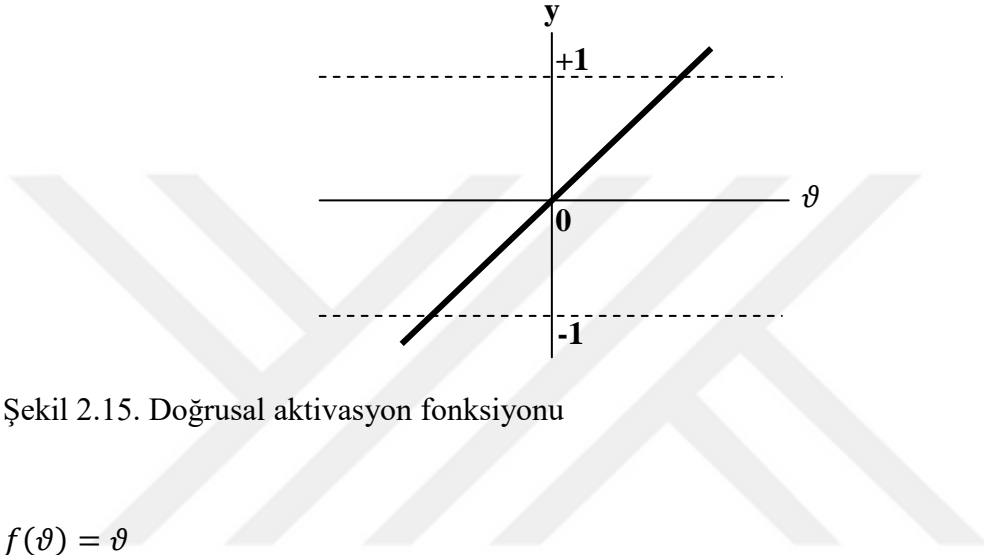
$$f(\vartheta) = \frac{e^{\vartheta} + e^{-\vartheta}}{e^{\vartheta} - e^{-\vartheta}} \quad (2.6)$$



Şekil 2.14. Hiperbolik tanjant fonksiyonu

### *Doğrusal fonksiyon*


Doğrusal aktivasyon fonksiyonu ağ girdi değerinin aynısını çıktı olarak verir. Doğrusal sistemlerin YSA ile modellenmesinde tercih edilen aktivasyon fonksiyonudur. Doğrusal aktivasyon fonksiyonuna ait denklem Eşitlik 2.7’de görülmektedir. Şekil 2.15’te ise doğrusal aktivasyon fonksiyonuna ait grafiksel gösterim bulunmaktadır.



### *Adım fonksiyonu*

Adım aktivasyon fonksiyonu, eşik değerinden küçük veya eşik değerine eşit ağ girdisi değeri için 0 sonucunu verirken eşik değerinden büyük ağ girdisi değeri için 1 sonucunu verir. Adım aktivasyon fonksiyonuna ait denklem Eşitlik 2.8’de; grafiksel gösterim ise Şekil 2.16’da görülmektedir.

$$f(\vartheta) = \begin{cases} 1, & \text{Eğer } \vartheta > T \\ 0, & \text{Eğer } \vartheta \leq T \end{cases} \quad (2.8)$$



Şekil 2.16. Adım aktivasyon fonksiyonu


### Çıktılar

Aktivasyon fonksiyonunun ürettiği sonuç değeri YSA çıktısı olur. Çıktılar tek başına YSA sonuç bilgisi olarak değerlendirilebileceği gibi diğer YSA hücre veya hücrelerine giriş olarak da verilebilir.

### **2.2.3 Yapay sinir ağı katman yapıları**

YSA tek katmanlı veya çok katmanlı yapıda olabilir. Tek katmanlı YSA basit ve doğrusal olarak ayrıştırılabilen problemlerin çözümünde kullanılırken çok katmanlı YSA daha karmaşık ve doğrusal olarak ayrıştırılamayan problemler için kullanılır. Doğrusal olarak ayrıştırılabilen problemlere AND ve OR problemleri örnek olarak verilebilirken, doğrusal olarak ayrıştırılamayan problemlere XOR problemi örnek olarak verilebilir. Minsky ve Papert (1969) tarafından yazılan kitap tek katmanlı YSA modelinin XOR problemine çözüm üretmediğini ortaya koymuştur (Sönmez Çakır, 2019). Bu durum YSA alanındaki çalışmalara büyük sekte vurmuş ve çalışmaların durma noktasına gelmesine sebep olmuştur. Çok katmanlı YSA modellerinin geliştirilmesiyle birlikte doğrusal olmayan karmaşık problemlere de çözüm üretilmesi YSA alanındaki çalışmaların yeniden ivme kazanmasını sağlamıştır.

Şekil 2.17’de sırasıyla AND, OR ve XOR problemleri için yapılan sınıflandırmalara ait grafiksel gösterimler bulunmaktadır. Koordinat düzleminde bulunan siyah ve beyaz noktalar; x ve y değişenlerinin değerlerini belirtmektedir.




Şekil 2.17. AND, OR ve XOR problemleri için sınıflandırma (a: AND problemi, b: OR problemi, c: XOR problemi)

Şekil 2.17’de bulunan grafikler,  $x$  ve  $y$  değişkenlerinin değerlerine göre çıktıları 0 ve 1 olarak sınıflandırmıştır. AND ve OR problemlerinde doğrusal sınıflandırma yapılabildiği, XOR probleminde ise doğrusal olmayan bir sınıflandırma yapılabildiği görülmektedir. Bu duruma göre AND ve OR problemlerinin tek katmanlı, XOR probleminin ise çok katmanlı bir YSA ile modellenebileceği anlaşılabilmektedir.

Tek katmanlı bir YSA modeli belirli sayıda girdiler ve bir tane çıktı katmanından oluşur. Çıktı katmanı bir veya daha çok nörondan oluşabilir. Her nöronun çıktıyı belirleyen aktivasyon fonksiyonuna ait giriş parametresi, girdilerin ağırlıklarla çarpılarak üzerine eşik değeri ilave edilmesiyle belirlenir (Öztemel, 2003). Eşik değeri çıktıların sıfıra eşit olmamasını sağlar.

Rosenblatt (1958) tarafından geliştirilen, girdi verilerinin ileri yönlü hareketi ile çıktı üretmesi modeline dayanan en basit tek katmanlı YSA modeli perceptron olarak adlandırılır (Sönmez Çakır, 2019). Perceptronlarda aktivasyon fonksiyonu olarak adım fonksiyonu kullanılır. Adım fonksiyonunun çıktısı, girdilerin ağırlıklarla çarpımlarının toplamının bir eşik değer ile karşılaştırılmasıyla elde edilir. Eğer toplama fonksiyonunun değeri eşik değerinden küçük ise çıktı 0 olurken; toplama fonksiyonunun değeri eşik değerine eşit veya eşik değerinden büyükse ağ çıktısı 1 olur. Şekil 2.18’de perceptron modelinin yapısı gösterilmektedir.



Şekil 2.18. Perceptron modeli (Gurney, 1996)

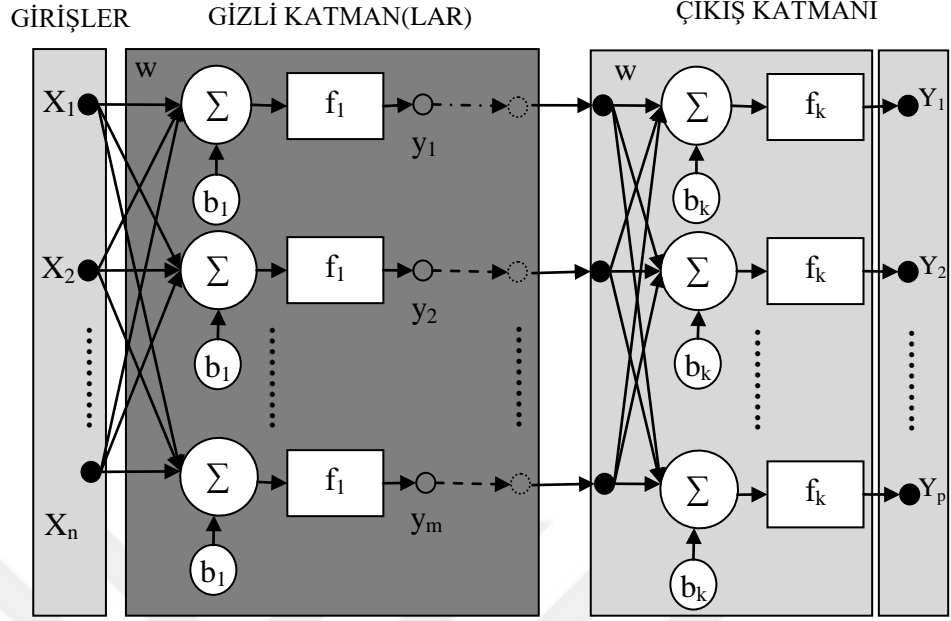
Eşitlik 2.9’da perceptron modelinde yer alan toplama fonksiyonunun denklemi bulunmaktadır. Eşitlikte  $a$  ile belirtilen toplam fonksiyonunun sonuç değeri aktivasyon fonksiyonu olarak kullanılan adım fonksiyonuna giriş parametresi olarak verilir. Ağın çıktısı Eşitlik 2.10’da yer alan denklem ile gösterilmiştir.

$$NET = \sum_{i=1}^n x_i w_i \quad (2.9)$$

$$f(NET) = \begin{cases} 1; & a \geq t \\ 0; & a < t \end{cases} \quad (2.10)$$

Çok katmanlı YSA modelinde ise; girdiler, gizli katmanlar ve çıktı katmanı bulunur. Gizli katmanda bir veya birden fazla katman bulunabilir. Bir gizli katmanda bulunan nöronların çıktıları yalnızca kendinden sonra gelen katmanda bulunan nöronlara girdi olarak verilir. Aynı gizli katman içerisinde bulunan nöronların birbirine bağlantıları yoktur (Haykin, 1999). Katmanlarda kullanılan aktivasyon fonksiyonları birbirinden farklı olabilmektedir.

Şekil 2.19’da çok katmanlı ileri beslemeli bir YSA modeline ait gösterim bulunmaktadır. Bilginin girişten çıkış katmanına doğru ileri doğru işlenmesine yönelik ağ yapısı ileri beslemeli olarak adlandırılır.



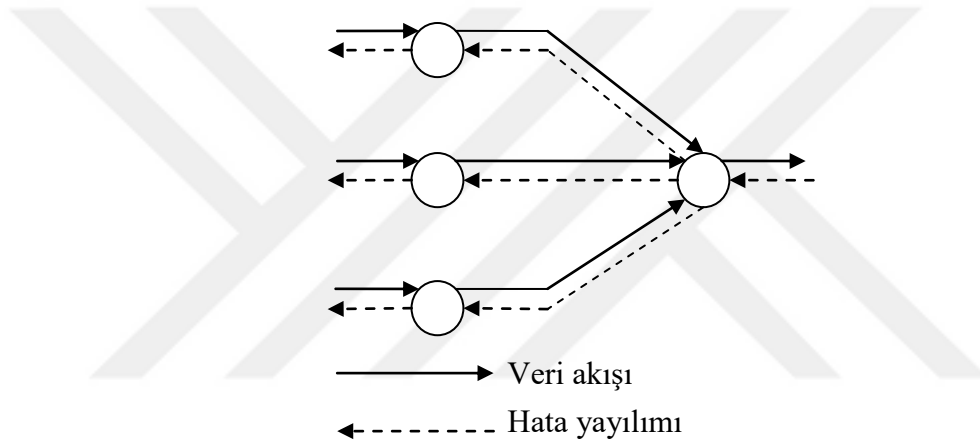
Şekil 2.19. Çok katmanlı ileri beslemeli YSA modeli

Çok katmanlı YSA modelinin karmaşık ve doğrusal olmayan problemlerin çözümünde etkili olması tek katmanlı YSA modeline göre avantaj sağlar. Çok katmanlı modelin dezavantajı ise işlem sürelerinin çok uzun olabilmesidir (Sönmez Çakır, 2019).

Gizli katman ağı kara kutusu olarak tanımlanır (Öztemel, 2003). Bu katmanda hangi işlemlerin yapıldığı tam olarak bilinmemektedir (Aktaş, 2003). Ağı öğrenmesi için yapılması gerekli işlemlerin en önemli ve büyük bölümü bu katmanda gerçekleşir. Bu katmandaki sinir hücresi sayısının fazla olması ağı ezberlemesine yol açabilir. Bu durum insan beyninde meydana gelen ezberleme ve öğrenme arasındaki farklılık ile benzeşim gösterir. Dışarıdan alınan bir bilgi insan beyninde eğer çok sayıda sinir hücresi kullanılarak hafızada tutulursa ezberlemeye yol açar. Eğer bu bilgiyi hatırlayabilmek için beyin, nöronlarda bulunan bilgilerden oluşturduğu bağıntıları kullanarak bir çıkarım yapabiliyorsa az sayıda nöron ile sonuca ulaşmış olur. Bu durum ise öğrenmedir. Ezberlemede ağ daha önce ezberlenmiş olan bilgiye benzer başka bilgilerle karşılaştığında bile hatalı sonuçlar verebilirken, öğrenmeyi gerçekleştirebilmiş ağ sahip olduğu bağıntı yapılarını kullanarak farklı verilerde de başarı oranı yüksek sonuçlara ulaşabilir. Bu özelliğinden ötürü çok katmanlı bir YSA modelinde gizli katman ağı zekâ bölümü olarak varsayılabilir (Soytürk, 2005).

#### 2.2.4 Geri yayılım algoritması

Çok katmanlı bir YSA modelinde Şekil 2.20’de görüldüğü gibi iki türde sinyal akışı gerçekleşir (Haykin, 1999). İlki ileri yönde olan veri sinyallerinin akışıdır ve giriş verileri en sonunda çıktıya dönüşür. Diğeri ise hata sinyalleridir. Üretilen çıktı değerleri olması istenen değerler ile karşılaştırılır. Aradaki fark hata sinyalleri olarak geri yayımlı olarak önceki katmanlara dağıtılır. Hata değerleri en aza indirilmeye çalışılır. Bu işlem çıkış katmanından giriş katmanına geri yönlü olarak yapılmaya çalışıldığından dolayı geri yayılım olarak isimlendirilir (Saraç, 2004).



Şekil 2.20. Veri akışı ve hata sinyalleri (Haykin, 1999)

Geri yayılım algoritmasının çok katmanlı ileri beslemeli YSA modeli için kullanımı oldukça yaygındır (Zhang ve Ark., 1998; Şen, 2004). Geri yayılım algoritmasında hatanın geriye yayılımı gradyan azaltımı ile yapılır. Bunun için aktivasyon fonksiyonlarına türev alma işlemi uygulanır. Bu işlem için aktivasyon fonksiyonunun türevi alınabilir nitelikte olması gerekmektedir.

Geri yayılım algoritmasında yapılan işlem adımları sırayla şu şekilde açıklanabilir (Lin ve Lee, 1996; Lawrance, 1997; Öztemel, 2003).

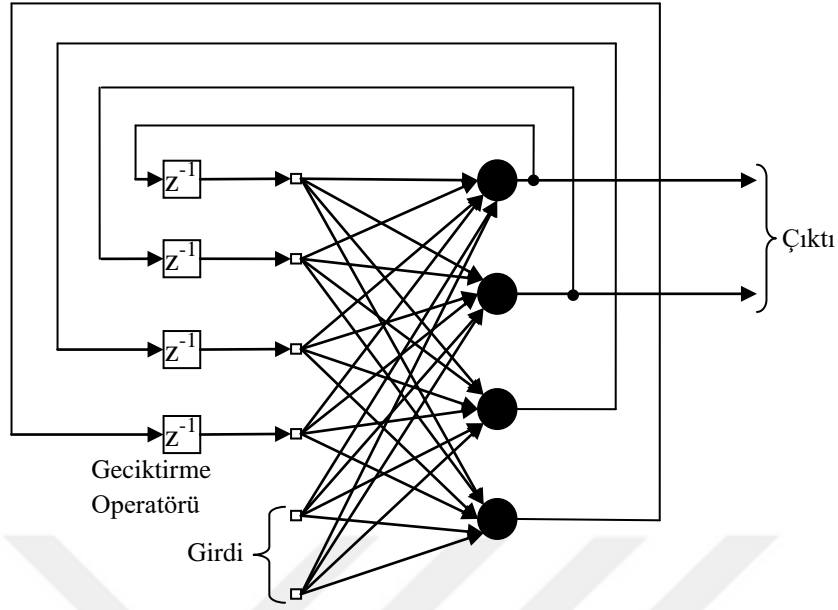
1. Katmanlara uygulanacak olan ağırlık değerleri belirlenir. Bu değerler rastgele seçilir.
2. YSA eğitimi için giriş verileri işleme alınır.

3. Türevi alınabilir doğrusal olmayan aktivasyon fonksiyonları yardımıyla giriş değerleri ileri yönlü olarak katmanlar arasında çıkış katmanına kadar aktarılır. Çıkış katmanında bulunan aktivasyon fonksiyonunun ürettiği değer çıkış değerini belirler.
4. Çıkış değeri ile olması gereken değer karşılaştırılarak hata değeri bulunur. Bu değer çıkış katmanından giriş katmanına doğru geri yönlü olarak ağdaki katmanlara yayılır.
5. Hata yayılımı sırasında katmanlardaki ağırlık ve eşik değerlerinin yayılan hata değerine göre değiştirilmesi sağlanır.
6. Bu işlemler YSA çıkış değerinin istenilen sınır değerinin altına ulaşana kadar tekrarlanır.

Eğitim setinde kullanılan verilerden bir tanesinin ağda işlemini tamamlaması bir iterasyon olarak tanımlanırken, eğitim seti verilerinin tamamının ağda işlemlerini tamamlamaları bir devir olarak ifade edilir. Geri yayımlı öğrenmede ağırlık değerlerinin değişimi her iterasyon veya her devir sonunda gerçekleşebilir (Öztemel, 2003).

### **2.2.5 Geri beslemeli yapay sinir ağları**


Geri beslemeli ağlarda aktivasyon fonksiyonu çıktıları bir sonraki katmanlardaki nöronların girişine verilebildiği gibi önceki katmanlardaki ya da aynı katmanda bulunan nöronlara da giriş olarak verilebilir (Haykin, 1999). Bu sayede YSA dinamik bir hafıza yapısına kavuşmuş olur. Böylece aynı hatalarla karşılaşıldığında hatayı belirleme ve geriye dönük olarak hata düzeltmesi yapabilme kolaylığına erişilmiş olur. Bu tipte ağ yapıları karmaşık bir yapıya sahip olmakla beraber ön tahmin gereken problemlerin çözümünde etkili sonuçlar üretirler. Şekil 2.21'de geri beslemeli YSA'ya ait bir gösterim bulunmaktadır.



Şekil 2.21. Geri beslemeli YSA (Haykin, 1999)

### 2.2.6 Öğretmensiz öğrenme

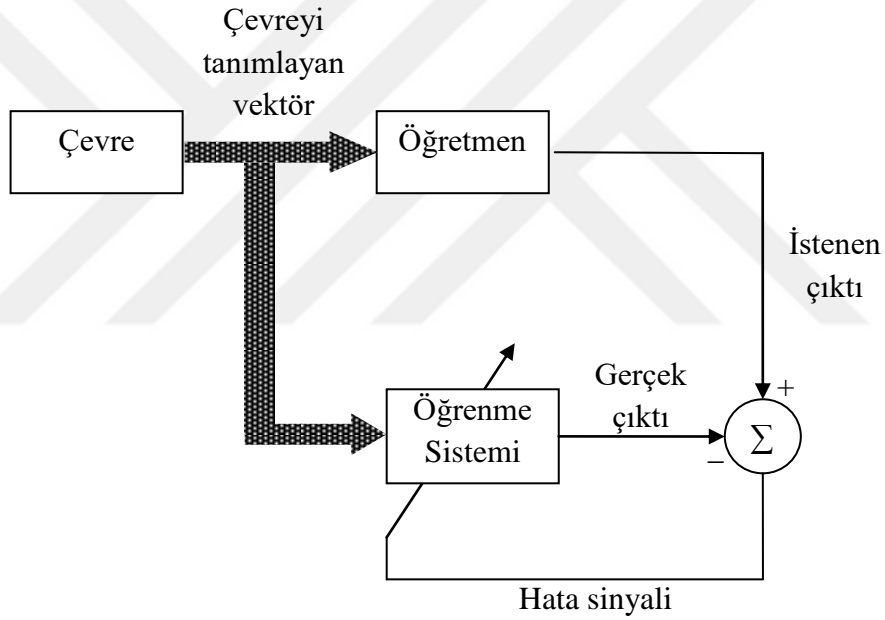
Öğretmenli öğrenmede öğrenme denetim unsuru vasıtasıyla yapılırken, öğretmensiz öğrenmede öğrenme sürecini denetleyen bir öğretmen bulunmaz (Haykin, 1999). Öğrenme sürecinde ağda yalnızca girdi verileri kullanılır. Öğretmenli öğrenmede girdi verilerine karşılık olması gereken çıktı verileri bulunurken, öğretmensiz öğrenmede çıktıların denetimini sağlayan olması gereken çıktı verileri yoktur. Ağa verilen giriş verilerinden türetilen çıktılarından ortak özellikte olanlar kendi aralarında gruplandırılır. Ağ yapmış olduğu bu gruplamaya göre bağlantı ağırlıklarını yeniden düzenler. Öğretmensiz öğrenme genellikle kümelemeye dayalı çalışmalarda tercih edilir (Öztemel, 2003). Şekil 2.22’de öğretmensiz öğrenmeye ait blok diyagram gösterilmiştir.



Şekil 2.22. Öğretmensiz öğrenme blok diyagramı (Haykin, 1999)

### 2.2.7 Öğretmenli öğrenme

Denetimli öğrenme olarak da adlandırılır. Öğretmenli öğrenmede ağın eğitimi için girdiler verilirken, bu girdilerle beraber olması gereken çıktılar da bellidir (Ataseven, 2013). Verilen girdilerin ağda ürettiği sonuçlar olması gereken çıktılar ile karşılaştırılarak hata payı bulunur. Bulunan hata değeri geri yayımlı olarak ağdaki bütün hücrelere paylaşılır ve ağırlık değerleri güncellenir. Önceden belirlenmiş olan girdi ve çıktı değerleri ağın eğitimi için bir nevi öğretmen görevi görmüş olurlar. Geri yayılım algoritması bu türde öğrenmeye örnek olarak verilebilir. Şekil 2.23'te öğretmenli öğrenme algoritmasına ait blok diyagram bulunmaktadır.

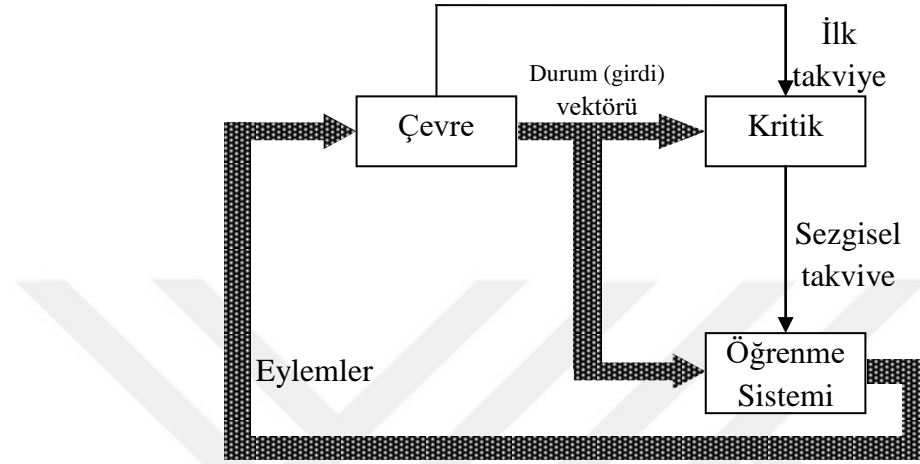


Şekil 2.23. Öğretmenli öğrenme blok diyagramı (Haykin, 1999)

### 2.2.8 Destekleyicili öğrenme

Bu öğrenme yönteminde öğrenmenin başarılı olup olmadığını belirleyen bir kriter bulunur. Kriter; ağın ürettiği çıktıyı doğru-yanlış veya başarılı-başarısız olarak değerlendirir (Şen, 2004). Başarısız çıktı üretildiğinde sonuç başarılı olana kadar eğitime devam edilir.

Destekleyicili öğrenme, öğretmenli öğrenmede olduğu gibi çıktıları denetleyen bir sistemdir. Ancak öğretmenli öğrenmede kullanılan girdi verilerine karşılık olması istenen çıktı verileri destekleyicili öğrenmede kullanılmaz (Sönmez Çakır, 2019). Şekil 2.24'te destekleyici öğrenmeye ait blok diyagram bulunmaktadır.



Şekil 2.24. Destekleyicili öğrenme blok diyagramı (Haykin, 1999)

### 2.2.9 Hebbian öğrenme

Hebbian öğrenme, nöropsikoloji alanında çalışmalar yapan Donald Holding Hebb tarafından 1949 yılında yapmış olduğu bir çalışmayla ortaya çıkmıştır. En temel YSA öğrenme kurallarından biridir. Hebbian öğrenmeye göre birbiriyle bağlı nöronlar aynı anda etkin başka bir deyişle aynı işarete sahiplerse bu nöronlar arasındaki bağlantıların ağırlıkları kuvvetlendirilmeleri gerekir. Aksi durumda bağlantı ağırlıkları düşürülmelidir (Kaftan, 2010).

### 2.2.10 Hopfield öğrenme

Bu öğrenme kuralı Hebbian öğrenme kuralıyla benzeşim gösterir. Eğer ağ içerisindeki birbiriyle bağlantılı girdi ve elde edilmesi istenilen çıktı değerleri aynı anda aktifse aradaki ağırlıkların bağlantısı öğrenme oranı ile artırılır. Aksi durumda ağırlık bağlantıları azaltılır (Sönmez Çakır, 2019). Öğrenme oranı 0 ile 1 arasında sabit bir değer alır (Durak, 2012).

### **2.2.11 Kohonen öğrenme**

Kohonen kuralına göre ağ içerisindeki bütün nöronlar en büyük çıktıyı elde etmek için birbiriyle yarışır. En büyük çıktıyı elde eden nöron yarışını kazanır. Bu nöronla birlikte bu nörona komşu olan nöronların da ağırlıkları değiştirilir (Bayır, 2006). Kohonen öğrenme kuralında çıktı denetimi yapılmaz. Bu yönüyle öğretmensiz öğrenme yöntemi sayılır. Kohonen öğrenme kuralında öğrenme sürekli. YSA çalışırken öğrenme devam eder.

### **2.2.12 Delta öğrenme kuralı**

Hebb kuralını temel alır. Bu kural ağın çıkış değeri ile istenilen çıkış değeri arasındaki hata değerinin geriye doğru yayılımı yapılarak ağırlıkların sürekli değiştirilmesi temeline dayanır. Hataların karelerinin ortalamaları en aza indirilmeye çalışılır (Kaftan, 2010). Bu kurala göre eğitim, sistem kullanımda olmadığı durumlarda gerçekleşir (Sönmez Çakır, 2019). En küçük ortalamaların karesi kuralı veya Widrow-Hoff kuralı olarak da adlandırılır (Kaftan, 2010).

### **2.2.13 YSA performansı değerlendirme ölçütleri**

YSA modellerinden elde edilen test sonuçlarını değerlendirmek için farklı hata değerlendirme yöntemleri bulunmaktadır. Bu yöntemlerde ağdan elde edilmek istenen çıktı değerleri ile ağın üretmiş olduğu çıktı değerleri arasındaki fark değerleri üzerinden hesaplamalar yapılarak ağın hata değeri belirlenir (Bayır, 2006). Belirlenen hata değeri YSA modelinin üretmiş olduğu çıktıların kabul edilebilir bir doğruluk oranına sahip olduğunu belirlemek açısından önemlidir (Sönmez Çakır, 2019). YSA modelleri tasarlanırken hata değerlerinin minimum seviyeye ulaşmış ve ulaşmadığı göz önünde bulundurulur. Ayrıca, YSA geri yayılım algoritmasında ağın eğitimi sırasında hesaplanan hata değerinin belirlenen ölçütlere ne kadar yaklaştığı değerlendirilerek ağırlıkların güncellenmesi sağlanır (Lawrance, 1997).

İleri beslemeli YSA modelleri için en çok kullanılan performans değerlendirme fonksiyonlarından biri Ortalama Hata Kareleri (Mean Square Error - MSE)'dir (Bayır, 2006). Eşitlik 3.12'de MSE değerinin hesaplamasına ait denklem bulunmaktadır.

$$MSE = \frac{1}{s} \sum_{t=1}^s (I_t - Y_t)^2 \quad (3.12)$$

Eşitlik 3.13'te Ortalama Hata Kareleri Karekökü (Root Mean Square Error - RMSE) hata belirleme yöntemine ait denklem bulunmaktadır.

$$RMSE = \sqrt{\frac{1}{s} \sum_{t=1}^s (I_t - Y_t)^2} \quad (3.13)$$

Eşitlik 3.14'te Ortalama Mutlak Yüzde Hata (Mean Absolute Percent Error – MAPE) hata belirleme yöntemine ait denklem bulunmaktadır. MAPE değeri yüzde olarak hata değerinin belirlenmesinde kullanılır (Sönmez Çakır, 2019). Lewis (1982)'e göre MAPE değeri, YSA sonuçlarının değerlendirilmesinde diğer hata oranı belirleme yöntemlerine göre daha etkin sonuçlar vermekte ve hata değerini açıklamak için yeterli olmaktadır.

$$MAPE = \frac{1}{s} \sum_{t=1}^s \left| \frac{I_t - Y_t}{I_t} \right| \times 100 \quad (3.14)$$

Denklemlerde kullanılan;  $s$  ağın çıktı değeri sayısını,  $I$  istenen çıktı değerlerini ve  $Y$  ağın ürettiği çıktı değerlerini ifade eder.

Hata değerleri dışında kullanılan bir başka performans değerlendirme ölçütü korelasyon katsayısı (R)'dir. R; değerlendirmesi yapılan iki değişkenin birbiriyle olan doğrusal ilişkinin belirlenmesinde kullanılır ve ilişki düzeyini belirleyerek iki değişkenin birbiriyle hangi oranda uyumlu olduğunun tespit edilmesini sağlar (Şahin, 2019). YSA modelinde çıktı değerleriyle olması istenen değerler arasındaki uyumu -1 ile 1 arasındaki değerler ile ifade eder. 1 veya -1 değerlerine yaklaşıldığı ölçüde iki değer arasındaki bağımlılığın yüksek olduğu değerlendirme yapılır. Değerlerin 0 ile 1 arasında olması isteniyorsa korelasyon katsayısının karesi olan belirleme katsayısı ( $R^2$ ) kullanılır (Doğan ve ark., 2008).

## 2.2.14 YSA avantaj ve dezavantajları

YSA'ların sağlamış olduğu bazı önemli avantajları şu şekilde sıralamak mümkündür:

- Problemlerin çözümünü gerçekleştirirken aynı zamanda öğrendikleri için kurmuş oldukları mantıksal bağıntılar ile benzer problemlere veya aynı olay için hiç karşılaşmadıkları örneklerle ilgili de çözüm bulabilirler (Efe ve Kaynak, 2004).
- Doğrusal olan veya doğrusal olmayan; çoklu girişli veya çoklu çıkışlı, tahmine dayalı sistemlere de çözüm sağlayabilirler (Yazıcı ve ark., 2007; Sönmez Çakır, 2019).
- Hata toleransına sahiptirler. Eksik veya hatalı bilgiler içeren örnek veri setleriyle bile çalışabilirler (Simpson, 1990).
- Matematiksel sistemlerin çözemediği, klasik yöntemlerle sonuç elde edilemeyen, karmaşık sistemlerde bile iyi sonuç verebilirler (Kaftan, 2010).
- YSA'ların eğitimi, eğitim örneklerinin durumuna ve yapısına bağlı olarak uzun sürebilse de paralel çalışma yapısı sayesinde problemlerin çözüm süreci kısa olabilir (Simpson, 1990).

YSA'ların bazı dezavantajlı yönleri şu şekilde sıralanabilir:

- Doğru sonuçlar elde etmek için kullanılan veri setindeki örnek sayısının fazla olması gerekebilir. Fazla sayıda veri toplamak yoğun uğraş ve zaman gerektirici olabilir (Kaftan, 2010).
- Eğitim süreci belirlenen problemin içeriği, belirlenen ağ yapısı ve veri setinin kapasitesine bağlı olarak uzun zaman alabilir (Kaftan, 2010).
- YSA'ların modellenmesinde ağ yapılarının oluşturulması, öğrenme algoritmalarının seçimi ve ağırlıkların belirlenmesi gibi konularda kesin kurallar bulunmamaktadır (Sönmez Çakır, 2019). Ağ tasarımı tecrübe ve deneme yanılma yöntemine dayalı olarak belirlenir (Yazıcı ve ark., 2007).

- Ađın eđitimi, ıktılar belirlenen sınır deđerin altına inince sonlanır. Ancak eđitim bittiđi zaman en iyi sonucun elde edilmiř olduđu tam olarak bilinemez (Sönmez akır, 2019).
- Ađda iřlenecek olan her türde verinin sayısal deđerlere evrilmesi gerekir (Öztemel, 2003).

### 2.3 Konu ile İlgili Literatürde Yer Alan alıřmalar

Mesafe ölçümü için aktif sensörleri ve pasif sensörleri kullanan yöntemler bulunur. Aktif sensörleri kullanan yöntemlerde nesnelere sinyaller gönderilerek mesafe ölçülür. Aktif sensör kullanan yöntemlere örnek olarak RADAR (Radio Detection And Ranging), LIDAR (Light Detection And Ranging) ve TOF (Time Of Flight) yöntemleri verilebilir. Lim ve ark. (2017)'a göre RADAR ve LIDAR sensörlü yaklařımlar yüksek performanslı deđerlendirmeler sađlasa da ok yüksek maliyete sahiptirler ve en az üç yılda bir periyodik olarak bakımları gerekmektedir. Ayrıca bu yöntem ile yayılan sinyallerin diđer araçların yaymıř olduđu sinyaller ile birbirlerine karıřma ihtimalleri vardır ve bu yaklařımların farklı tipteki engelleri ayırt etmede zorlandıđı gözükmemektedir (Lim ve ark., 2008). Bu sebeplerden ötürü aktif sensör tabanlı sistemler engel tespiti ve mesafe ölçümü için akademik alıřmalarda tercih edilmezler (Emani ve ark., 2019).

Pasif sensörlere örnek olarak kameralar verilebilir. Pasif yöntem; deđiřken hava ve ışık kořullarının bulunduđu ortamlarda, yüksek özünürlüklü ve aktif sensörlere kıyasla düşük maliyetli kameralarla alıřabilme avantajına sahiptir (Häne ve ark, 2015). Kamera tabanlı teknolojiler kullanarak görüntü sensörleriyle alıřan bir yaklařımın avantajı belirlenen nesnenin ayrıntılı bilgilerine ulařılabilmesidir. Bu sayede ön nesnelere algılanabilir ve tanınabilirler. Ayrıca bu bilgiler kullanılarak görüntü iřleme teknikleri ile belirlenen nesnenin uzaklıđının ölçümü gerekleřtirilebilir.

Görüntü sensörleri ile mesafe bilgisine ulařılması için elde edilen görüntülerin ön iřlemlerden geirilmeleri gerekir. Bu iřlemler resimdeki nesnenin boyutuna veya konumuna ait bilgiler kullanılarak yapılır (Park ve Hwang, 2014). Kamera tabanlı uygulamaların kısa mesafelerde yapılan ölçümlerinde hata oranı düşük iken uzun

mesafeler için yapılan ölçümlerinde daha fazla hata oranı oluşur. Bu sorun kameranın objektif alanındaki piksel sayısı artırılarak çözülebilse de bu durum hem maliyeti hem de sistem karmaşıklığını artırır (Lim ve ark., 2008). Görüntü işlemeyi kullanarak mesafe ölçümü bilgisayarlı görme için en önemli araştırma konularından biridir (Alizadeh ve Zeinali, 2013). Aktif sensörlere göre düşük maliyetli olması, gelişmiş hesaplama platformları ve optimize edilmiş görüntü işleme algoritmalarının getirdiği avantajlar düşünüldüğünde gerçek zamanlı yakalanan görüntü verileri ile bir otomobilin çevresini haritalandırmak ve öndeki araçla olan mesafesini tahmin etmek için kameralardan yararlanılabilir. Pasif sensör tabanlı yaklaşımların aktif sensör tabanlı yaklaşımlara göre yazılım tasarımları daha karmaşıktır. Bu nedenle pasif sensör tabanlı yaklaşımlarda yüksek performanslı ve gerçek zamanlı görüntü işleme algoritmaları yazılımların odak noktalarındandır (Liu ve Chen, 2009).

Pasif sensör uygulamalarından monoküler kamera olarak da adlandırılan tek kamera kullanılarak yapılan uygulamalar görüntü işleme ve nesnelere tanımlamak için karmaşık görüntü işleme algoritmalarına gereksinim duyar. Ayrıca monoküler tabanlı yaklaşımlar için mesafesinin ölçümü yapılacak hedef nesnenin boyutuna ait bilgilerin önceden bilinmesi gerekir. Bu tür bir bilginin önceden bilinmesi imkansız olabilir (Lim ve ark., 2008). Bu türde uygulamaların mesafe ölçümündeki yüksek hata oranlarından dolayı ticari uygulamalarda tercih edilmeleri uygun değildir (Lim ve ark., 2017).

Diğer pasif sensör uygulamalarından stereo kamera olarak da adlandırılan iki kamera kullanılarak yapılan uygulamalarda ise, monoküler kamera ile yapılan uygulamalara göre daha az karmaşıklık seviyesinde algoritmalar kullanılabilir (Emami ve ark., 2019). Ayrıca düşük maliyetli web kameralar kullanılabilir. Eğer görüntü yakalamak için tek bir kameradan yararlanılıyorsa mesafe ölçümü gibi hesaplamalar için görüntü yalnızca bir bilinmeyen ölçek faktörüne göre ayarlanabilir (Pollefeys ve ark., 2007). Uzaysal düzlemde anlık çevresel verilere ihtiyaç duyulduğu üç boyutlu uygulamalar için bu durum problem oluşturur. Bu sorun stereo tabanlı yaklaşımlar kullanılarak çözülebilir (Fathi ve Brilakis, 2014). İnsan da stereo görme sayesinde nesnelere mesafelerini kabaca tahmin edebilir (Hsu ve Wang, 2015). Bu duruma benzer bir şekilde stereo kameraların kullanılması nesnelere derinlik bilgisine ulaşma imkanı verebilir (Salman ve ark., 2017). Ancak belirtmek gerekir ki, hiçbir bilgisayarlı görme sistemi; görüntü

anlamlandırma ve ışık değişikliklerine karşı gösterilen tolerans gibi insan görme sisteminin bazı özelliklerini karşılayamaz (Ashoori ve Mahlouji, 2017). Bu türde uygulamalar her ne kadar monoküler kameralara göre daha fazla işlem süresine sahip olsalar da iki resim arasındaki eşitsizlikten ortaya çıkarılan ayrıntılı bilgilerden yararlanarak özellikle nesnelerin yüksek uzaklıktaki mesafelerine yönelik monoküler kameralara kıyasla yüksek doğruluk oranına sahip tahminler gerçekleştirir (Kehtarnavaz ve ark., 1991). Örneğin nesnenin iki kameradan alınan görüntülerdeki konumunun göreceli farkı kullanılarak mesafe ölçümü hesaplanabilir (Mrovlje ve Vrancic, 2008). Stereo kamera kullanılan pasif sensör uygulamaları otomatik sürüş sistemleri için idealdirler. Ayrıca eğitim ve araştırma alanlarında kullanımları elverişlidir.

Bu bölümde bu tez çalışmasının konusuyla ilgili literatürde bulunan pasif sensör kullanarak yapılmış çalışmaların özeti sunulmuştur. Karayolu trafiğinde bulunan bir araçtan öndeki aracın mesafesini ölçmeye yönelik literatürde yer alan çalışmalar incelendiğinde, kamera kullanılarak yapılan çalışmaları tek kamera ile yapılan çalışmalar ve iki kamera ile yapılan çalışmalar olmak üzere ikiye ayırmak mümkündür. Bölümün ilk iki başlığında sırasıyla tek kamera kullanılarak yapılan çalışmalar ve iki kamera kullanılarak yapılan çalışmalar sunulmaktadır. Bölümün son başlığında ise yapılan çalışmanın literatüre katkısı hakkında bilgilendirme yapılmaktadır.

### **2.3.1 Tek kamera kullanılarak yapılan çalışmalar**

Chang ve Cho (2006); tek kamera kullanarak karayolunda bulunan öndeki araçların tespitini yapan ve mesafelerini hesaplayan bir çalışma yapmışlardır. Çalışmada Adaptif Rezonans Teorisi (ART) isimli bulanık kural tabanlı bir algoritma geliştirilerek görüntünün karayolu, gökyüzü ve diğer kısımlar olarak bölümlere ayrılması sağlanmıştır. Görüntünün bölümlere ayrılmasını sağlayan algoritma, özelliklerine göre görüntü piksellerinin hangi gruba üye olduğunu belirlemektedir. Araç olma ihtimali olan bölgeler belirlenirken üç aşamada işlem yapılmıştır. Birinci aşamada daha önce bölümlere ayrılan görüntünün yalnızca yol bölümü için araç olma ihtimali olan bölgelerin değerlendirilmesi yapılmaktadır. İkinci aşamada araç olma ihtimali olan bölgelerin altında bulunan gölgeler piksel renk değerlerine göre belirlenmektedir.

Üçüncü aşamada ise araçların yükseklik-genişlik oranının belirli bir aralıkta olduğu kabul edilmiştir. Bu oran doğrultusunda daha önce belirlenen araç gölgeleri alt sınır kabul edilerek üzerinde araç olma ihtimali olan bölgeler dikdörtgenlerle temsil edilmiştir. Belirlenen araçların mesafelerinin tahmin edilmesi için öncelikle kameranın yerleşiminin açısal olarak ayarlanması sağlanmaktadır. Odak uzaklığı ve yüksekliği bilinen kameranın görüntü modeli üzerinde üç boyutlu derinlik hesabı yapılarak öndeki araca olan mesafenin tahmini değeri bulunmaktadır. Mesafe tahmini sonuçları aynı araç üzerinde bulunan bir radar sistemiyle yapılan ölçüm sonuçlarıyla karşılaştırılmıştır. Karşılaştırma işlemi radar sisteminin ölçümlerine göre 6.23 metre ile 34.48 metre arasındaki değişik aralıkta alınan 20 örnek üzerinden yapılmıştır. Yaklaşık 27 metreye kadar yapılan ölçümlerde %5.46'dan daha az hata oranları tespit edildiği ifade edilmiştir. 27 metreden sonra ise hata oranları belirgin ölçüde artmaktadır. 8 metre ile 27 metre arasında mesafe tahmininin daha iyi bir doğruluk oranına sahip olduğu ifade edilmektedir.

Bas (2007); yapmış olduğu çalışmayla karayolu trafiği ile ilgili video görüntülerini işlemeye dayalı iki farklı sistem sunmuştur. Birinci sistemde sabit bir kamera üzerinden Gaussian Mixture Model tabanlı bir arka plan çıkarım yöntemi uygulayarak, araçların belirlenmesi ve takip edilmesini sağlayan bir karayolu trafiği izleme yöntemi sunulmuştur. Önerilen yöntem; araçların belirlenmesi ve takibi için öncelikle yol maskesi uygulayarak hesaplama karmaşıklığını düşürür. Daha sonra araç boyutlarını kullanarak yeni bir örtüşme algoritma tekniği uygular. İkinci sistemde ise; ana araç üzerine yerleştirilen sabit bir kameradan, yol şerit çizgileri kullanılarak öndeki hedef araçların yerlerini belirleyen ve bu hedef araçların mesafesini tespit etmeyi amaçlayan bir yöntem sunulmuştur. Önerilen yöntemde öncelikle şerit işaretlerinin belirlenmesi için, şerit işaretlerinin kenar kısımlarını öznitelik olarak belirleyen bir kümeleme algoritması uygulanmıştır. Öndeki aracın mesafesinin tahmin edilmesi için, öznitelikleri bilinen sağ ve sol şerit çizgileri arasındaki mesafe ile görüntü üzerinde yeri belirlenen araç bölgesi genişliği arasında piksel sayılarının karşılaştırılmalarını içeren bir hesaplama tekniği kullanılmıştır. Önerilen yöntemin araç lokalizasyonunu %1.25 hata oranı ile tahmin edebildiği ifade edilmiştir.

Kim ve Cho (2012); yapmış oldukları çalışmada, araç içerisine yerleştirmiş oldukları sabit bir kameradan alınan gerçek zamanlı görüntülerden öndeki araçların algılanmalarını sağlayan ve mesafelerini ölçebilen bir yöntem geliştirmişlerdir. Araç tanıma için kullanılan Haar-Like nesne tanıma algoritmasında araç arka bölgeleri gölgelerinin yoğunluk özelliklerini ve kenar özelliklerini temel alan yaklaşımların birleşimini kullanır. Mesafe tahmin yönteminde ise öndeki aracın konumunu ve genişliğini temel alan iki farklı yöntemin avantajlarını kullanan bir algoritma kullanılmıştır. Genişliği temel alarak mesafe tahmini yapan yöntemde araç genişlikleri için ortalama bir değer belirlenmesi gereklidir. Aracın konumunu temel alan yöntemde kameranın önceden bilinen odak uzaklığı ve yükseklik değerlerine göre öndeki aracın konumunu ve uzaklığını tahmin etmek mümkündür. Ancak bu yöntem gürültülü görüntülerde iyi sonuç vermeyebilir ve zeminin düz olmadığı durumlar kamera yüksekliğine göre yapılan hesaplamada hata oranının yüksek olmasına neden olur. Önerilen birleştirilmiş yöntem; konuma dayalı yöntem hesaplamalarını genişliğe dayalı yöntem içerisine entegre ederek iki yöntemin olumsuz etkilerini indirgemeyi sağlar. Önerilen yöntemin araç tanıma performansını ölçmek için yapılan testte, içerisinde araçların bulunduğu 1000 adet görüntü örneğinde bulunan 3335 araç bölgesinden 3138 tanesinin tespit edilerek %94.9 başarı oranına ulaşıldığı belirtilmiştir. Mesafe tahmini yönteminin doğruluğunu ölçmeye yönelik yapılan testte, 35 metreye kadar belirli aralıklara ait 11 tane görüntü örneğinin değerlendirilmesi grafiksel olarak sunulmuştur. Grafik; mesafe ölçüm cihazı sonuçları ve önerilen yöntem tahminlerini karşılaştırmaktadır. Önerilen yöntemin mesafe tahminindeki hata oranının uzak mesafelerde arttığı belirtilmiştir. Yöntemin sadece gündüz koşullarında çalışmaya uygun olduğu, mesafe tahmin algoritmasının karanlık ortamlar için uygun olmadığı ifade edilmektedir.

Wu ve ark. (2013); aracın sol dikiz aynasına yerleştirmiş oldukları bir kamera vasıtasıyla yan şeritteki arkadan gelen araçları tespit eden ve bu araçların mesafelerini tahmin eden bir çalışma ortaya koymuşlardır. Önerilen yöntemde öncelikle görüntü işleme teknikleri kullanılarak şerit çizgilerinin tespiti sağlanmıştır. Yan şeritte; kenarları, belirlenen şerit çizgileri ile oluşturulan 30 metre uzunluğunda ve genişliği şerit genişliği kadar olan bir alan oluşturulmuştur. Araç olma ihtimali olan bölgeler yan şeritteki bu alan içerisinde aranmaktadır. Uzunluk, genişlik, süre ve yükseklik

parametrelerine göre araç olma ihtimali olan bölgeler doğrularak belirlenmektedir. Son olarak, tasarlanan bir sinirsel bulanık ağ modeli ile belirlenen araçların mesafelerinin tahmini yapılmaktadır. Sinirsel bulanık ağ modeli; girdi verileri olarak görüntüdeki hesaplanan piksel uzaklığı değerlerini, çıktı verileri olarak ise gerçek uzaklık ölçüm değerlerini alarak eğitilmektedir. Verileri elde etmek için 2 metre ile 30 metre arasında 2 metre aralıklarla yapılan kamera çekimi örneklerinden elde edilen mesafe ölçümü değerleri kullanılmıştır. 500 iterasyon ile gerçekleştirilen eğitim süreci sonunda çıktı verilerinin RMS hata değeri 0.398905 olarak belirlenmiştir. Ayrıca şerit belirleme ve araç tespitine ait sonuçlar, karayolu üzerinde sürüş yaparken çekilen dokuz video dizisiyle test edilmiştir. Video dizilerinin başarımları; araç tespiti için %62 ile %95 arasında, şerit tespiti için %95 ile %99 arasında değişmektedir.

Park ve Hwang (2014); yapmış oldukları çalışmada araç üzerine yerleştirilen bir kameradan alınan görüntülerle yol eğiminin değişmesi ve şerit işaretlerinin görülebilmesi durumunda dahi mesafe bilgisi sağlayan bir tahmin yöntemi geliştirmişlerdir. Önerilen yöntem ile şerit işaretleri kullanılarak ufukların belirlenmesine dayalı mesafe tahmin yöntemlerindeki, araçların sürekli hareket halinde olması ve yol eğiminin değişken olması sebebiyle kamera eğim açısının değişken olmasından kaynaklı mesafe tahmin sorununa çözüm bulunmaya çalışılmıştır. Tespit edilen araçların büyüklük ve konum bilgileri kullanılarak sanal ufukları belirlenmiştir. Araçların genişliği için sabitlenmiş ortalama bir değer (örneğin 1.82 metre) belirlenerek hesaplamalarda bu değer kullanılmıştır. Daha sonra tahmini sanal ufukları belirlenmiş olan araçların konumlarından mesafe bilgileri tahmin edilmektedir. Karayolunda ve kentsel trafik yollarında çekilen video görüntüleri kullanılarak önerilen yöntemin değerlendirilmesi yapılmıştır. Tahmin edilen sanal ufuk ve mesafe değerlerinin, görüntü üzerinden manuel olarak belirlenen sanal ufuk ve ölçülen mesafe değerleriyle karşılaştırması yapılmaktadır. Araçların genişliğine göre belirlenen sanal ufuklar üzerinden mesafe tahmini yapılması; araç genişliğinin ortalama sabit bir değer belirlenmesinden dolayı çok büyük veya küçük ölçekli tek bir aracın bulunduğu görüntülerde %30 hata oranına varan tahmin sonuçlarının oluşmasına yol açtığı ifade edilmektedir. Mesafe tahmininin 50 metreye kadar yapılabildiği, 50 metreden sonra araç tespitinin zorlaşmasından dolayı sistemin hata verebileceği belirtilmektedir.

Kısa (2014); yapmış olduğu tez çalışmasında, bir araca monte etmiş olduğu sabit bir kameradan aldığı görüntülerden faydalanarak önde bulunan araçların tespit edilmesini, mesafelerinin tahminini ve hızlarının hesaplanmasını içeren bazı yöntem ve teknikleri sunmaktadır. Önerilen yöntemde ilk olarak elde edilen görüntülerden araç olma ihtimali olanları belirlemek için görüntü işleme teknikleri ile görüntülerdeki kenar çizgilerinin belirlenmesi sağlanmıştır. Bu işlem için sırasıyla; Gaussian metodunu kullanarak gürültü giderme, gri renk seviyesine dönüştürme ve ardından ikili sayısal görüntüye dönüştürme işlemleri yapılmıştır. Daha sonra Canny kenar belirleme algoritmasıyla elde edilen görüntülerde bulunan kenar çizgileri belirlenmektedir. Hough ve Harris & Stephens algoritmaları kullanılarak kenar çizgileri belirlenen görüntülerdeki araç olma ihtimali bulunan bölgeler tespit edilmektedir. Araç olma ihtimali olan bölgeler görüntü içerisinde plaka alanı dikdörtgenlerinin bulunup bulunmamasına göre belirlenir. Plaka alanı dikdörtgenlerinin tespit edilmesi işlemi ise önceden bilinen plaka en ve boy sabit değerleri oranlamasına göre yapılmaktadır. Mesafe tahmini için; belirlenen plaka bölgesi dikdörtgeninin görüntüdeki piksel cinsinden yüksekliği ile mesafe tahmininin cm cinsinden değerinin orantılı olduğu kabul edilen bir bağıntı kullanılmaktadır. Orantıyı belirlemek için, kamera kalibrasyonu sonrasında bir görüntü örneği alınmış ve bu örnek görüntüde yer alan öndeki araca ait mesafenin ölçümü yapılmıştır. Örnek görüntüde belirlenen plaka yüksekliğinin piksel cinsinden değeri ile ölçülen mesafenin cm cinsinden değeri, elde edilen diğer görüntülerde yer alan araçların plakalarının yüksekliğinin piksel cinsinden değerleri ile ilişkilendirilerek mesafe tahmini için oluşturulan bağıntıda kullanılmaktadır. Mesafe tahmin sonuçlarının değerlendirilmesi 1 metre ile 90 metre arasında elde edilen 12 adet görüntü örneği üzerinden yapılmıştır. Bulunan mesafe tahmini sonuçları; şeritmetre ve lazermetre ile yapılan mesafe ölçümü sonuçlarıyla karşılaştırılarak bir değerlendirme yapılmaktadır. Belirlenen mesafe tahmini sonuçlarının şeritmetre ile yapılan ölçüm sonuçlarına göre; 1 metre ile 25 metre aralığı için %0.4 ile %4.96 arasında değişen hata oranlarına sahip olduğu görülmektedir. 25 metreden daha yüksek mesafelerde hata oranının %5'i geçtiği; 35 metreden daha fazla mesafeler için ise plaka bölgesinin tespitinin yapılamadığı ifade edilmektedir.

Han ve ark. (2016); yapmış oldukları çalışmada monoküler kamera modeli ile bir araçtan diğer aracın pozisyon, hız ve çarpışma süresi bilgilerini tahmin edebilen bir algoritma geliştirmişlerdir. Bu yöntem tespit edilen şerit çizgisi bilgilerine ve iğne deliği

kamera modeline göre öndeki aracın genişliğine ait olan iki tahmin gerçekleştirir. Birinci yaklaşımda, tespit edilen şerit çizgileri bilgileri kullanılarak aracın görüntü genişliği tahmin edilir. Elde edilen aracın görüntü genişliği bilgileri ise aracın pozisyonu, hızı ve ivmesini içeren ölçüm sinyallerinin tahmini için kullanılır. Daha sonra bir Kalman filtresi ile hedef aracın; pozisyonu, hızı ve ivmesi takip edilmektedir. Son olarak da çarpışma zamanı tahmini yapılmaktadır. İkinci tahminde şerit işaretleri belirlenmemiş olsa da aracın ölçüm sinyalleri araç genişliğine göre belirlenebilmektedir. Bu yöntemde araç genişliği, belirlenen ufuk çizgisi kullanılarak bulunan araç görüntü yüksekliği ile tahmin edilmektedir. Bu yaklaşım şerit çizgilerinin geçerli olmadığı durumlarda bile ölçüm sinyalleri için tahmin gerçekleştirebilir ancak bu durumda tahmin edilen ufuk çizgisinin hata oranı artmaktadır. Şerit çizgileri belirli olmadığında ufuk çizgisi, tespiti yapılan aracın genişliği kullanılarak tahmin edilmektedir. Bir Kalman filtresi ile hedef aracın; pozisyonu, hızı ve ivmesi takip edilmektedir. Bu bilgiler kullanılarak çarpışma süresi tahmini yapılmaktadır. Son olarak iki yaklaşım ile belirlenen ölçüm sinyallerinin tahmini sonuçları birleştirilmektedir. Tahmin sonuçlarının değerlendirilmesi için önden görüntü elde edebilen bir kameraya sahip lazer tarayıcı barındıran bir test cihazının ürettiği veriler kullanılmaktadır. Testler deneme yollarında ve normal yollarda olmak üzere iki farklı şekilde sunulmaktadır. Ayrıca testler yapılırken araçların tespiti için üç farklı yöntem kullanılmış ve değerlendirmeler bu üç yöntem için de ayrı ayrı yapılmıştır. Bu yöntemler araç bölgelerinin; görüntü üzerinden manuel olarak belirlenmesi, araç algılama algoritması kullanılarak belirlenmesi ve test cihazı ile belirlenmesidir. Deneme yollarında manuel olarak belirlenen araç bölgeleri ile yapılan testlerin sonuçlarının performans olarak yüksek olduğu belirtilmiştir. 0 metre ile 45 metre arasındaki araçların dikey konum uzaklığı tahmin sonuçlarının hata oranının %2.9 ile %6.6 arasında olduğu belirtilmektedir. 45 metre ile 90 metre arasındaki araçların dikey konum uzaklığı tahmin sonuçlarının %0.59 ile %5.4 hata oranına, 90 metreden daha fazla uzaklıkta olan araçların dikey konum uzaklıklarının tahmin sonuçlarının ise %3.5 ile %3.9 arasında hata oranına sahip olduğu belirtilmiştir. Bu sonuçlara kıyasla araç algılama algoritması kullanılarak yapılan tahmin sonuçlarının performansının oldukça düşük olduğu ifade edilmektedir. Önerilen sistemin daha iyi sonuçlar verebilmesi için araç algılama algoritmasının geliştirilmesi gerektiği ifade edilmektedir. Ayrıca sistemin şerit

çizgilerinden bağımsız olarak her zaman hassas sonuçlar verecek şekilde geliştirilmesi gerektiği ifade edilmektedir. Son olarak değerlendirme verilerinin ve test senaryolarının artırılması gerektiği ifade edilmektedir.

Liu ve ark. (2017); tek kameradan elde edilen görüntülerden şerit belirleme, araç takibi ve mesafe tahmini yapabilen bir çalışma yapmışlardır. Çalışmalarında ilk olarak kullanmış oldukları RANSAC algoritması ile şerit çizgilerinin belirlenmesini sağlamışlardır. Daha sonra uygulanan KALMAN filtre yöntemi belirlenen şerit çizgilerinin takibi için kullanılmaktadır. Bir ADABOOST sınıflandırıcı kullanılarak tespit edilen araçların çoklu takibi, kullanılan bir parçacık filtre yöntemi ile gerçekleştirilmektedir. ADABOOST sınıflandırıcısı 784 pozitif görüntü ve 7762 negatif görüntü içeren 20 basamaklı aşama ile eğitilmiştir. Son olarak şerit çizgilerinin düzenleniş biçimlerine göre konumları ölçülebilen birkaç standart nokta ayarlanarak doğrulanabilen bir mesafe tahmin yöntemi sunulmaktadır. Karayollarındaki şerit çizgilerinin 4 metre ve şerit çizgileri arasındaki boşlukların 6 metre olduğu varsayılmaktadır. Bu varsayımdan hareketle görüntüde yer alan şerit çizgileri üzerinde ayarlanan noktalara göre araçların konumları değerlendirilerek mesafe tahmini yapılmaktadır. Önerilen çalışmanın sonuçları otoyollardan alınan görüntü dizisi örneklerinin üzerinde yapılan değerlendirmeler ile test edilmiştir. Yapılan çalışmanın sonuçları; şerit belirleme ve izleme, araç algılama ve izleme, mesafe tahmini olmak üzere üç bölümde değerlendirilmektedir. Mesafe tahmini için sonuçların değerlendirilmesi video görüntülerinden elde edilen 1000 görüntü çerçevesi kullanılarak yapılmıştır. Yapılan değerlendirmede; 10 metreden daha düşük uzaklıktaki araçların mesafe tahminleri için 0.74, 10 metre ile 20 metre arasındaki uzaklıklarda bulunan araçların mesafe tahminleri için 1.77 ve 20 metreden daha fazla uzaklıktaki araçların mesafe tahminleri için 6.52 ortalama hata değerlerine ulaşıldığı belirtilmektedir.

Huang ve ark. (2017); yapmış oldukları çalışmada tek lensli bir video kamera yardımıyla araçların algılanmasını sağlayan ve algılanan araçların mesafelerini tahmin edebilen bir sistem sunmuşlardır. Çalışmada öncelikle video görüntülerindeki zamansal farktan yararlanılarak hareketsiz alanlar çıkarılmaktadır. Ardından şerit çizgilerinin yardımıyla ufuk noktası belirlenmektedir. Belirlenen ufuk noktası ve şerit çizgileri yardımıyla yol bölgelerinin bölümlenmesi yapılmıştır. Araçların altındaki gölgelerden

faýdalanılarak tespit edilen araç bölgeleri, yönlendirilmiş gradyanların histogramı (HOG) ve bir SVM sınıflandırıcı methoduyla da onaylanmaktadır. Belirlenen araçların mesafelerinin tahmini için tespit edilen ufuk noktası ve araç bölgelerinin konumları arasındaki bağıntı kullanılmaktadır. Sonuçların değerlendirilmesinin değişik hava koşullarında çekilen 5 video kaydından elde edilen görüntü dizileri ile yapıldığı belirtilmiştir. Bu 5 farklı ortamdan alınan görüntü sonuçlarının değerlendirmesinde araç tespiti için, %73.63 ile %94.08 arasında başarı oranına ulaşıldığı ifade edilmektedir. Mesafe tahmini için doğruluk oranı ortalamasının %87.8 olduğu belirtilmektedir.

### **2.3.2 İki kamera kullanılarak yapılan çalışmalar**

Ito ve ark. (1992); yapmış oldukları çalışmada aralarında sabit bir mesafe bulunan optik eksenleri birbirine paralel iki kameradan elde edilen bir görüntü çiftini kullanarak karayolu mesafe tahmin uygulaması yapabilen ve video görüntü hızına uyum sağlayabilen bir algoritma sunmuşlardır. Çalışmada; önermiş oldukları algoritmanın video hızına uyum sağlayabilmesi için stereo görüntü işleme tekniklerinin getirmiş olduğu yüksek hesaplama maliyetini düşüren iyileştirmeleri sağlayan bazı yöntem ve teknikleri içerdiği ifade edilmektedir. Temel mesafe tahmini hesaplama yönteminin, sabit bir değer ile belirlenmiş olan uzunluğun uçlarında bulunan iki kamera merceği merkezleri ile kamera görüntülerinin kesişen bölgelerinde yer alan hedef noktanın köşelerini oluşturduğu bir üçgenleme modeline dayandığı ifade edilmektedir. Hedef noktanın belirlenmesi, iki kameradan alınan görüntülerin görüntü yoğunlukları kullanılarak özellik çıkarımına dayalı bir yöntem ile sağlanmaktadır. Daha sonra elde edilen görüntülere görüntü eşleştirme yöntemi uygulanarak iki görüntünün birbirine karşılık gelen özellikleri mesafe tahmin hesabında kullanılır. Önerilen yöntemin mesafe tahmin sonucunu değerlendirmek için, önde bulunan 8 metre uzaklıktaki bir aracın aralarında sabit bir mesafe bulunan optik eksenleri birbirine paralel iki kameradan alınan görüntüleri kullanılmıştır. Yapılan grafiksel değerlendirmede mesafe tahmin yönteminin 8 metreye oldukça yakın bir sonuç verdiği belirtilmiştir.

Bertozzi ve ark. (2000); bir araç üzerine kurulu bir stereo kamera sisteminden elde ettiği gri seviye görüntülerden faydalanarak otonom sürüş için algılama ve izleme işlemleri

yapabilen yöntem ve teknikleri içeren bir çalışma sunmuşlardır. Çalışmada tek kameradan elde edilen görüntü dizisi ile öndeki aracın yerinin belirlenmesi ve izlenmesi gerçekleştirilirken stereo kameradan alınan görüntüler kullanılarak mesafe tahmini yapılmaktadır. Görüntüde yer alan öndeki araç bölgesinin yerinin belirlenmesi için bir araçların genellikle simetrik olduğu yaklaşımdan hareketle simetrik özelliklerin belirlenmesine dayalı görüntü işleme tekniği kullanılmaktadır. Bunun için öncelikle görüntüdeki yatay ve dikey kenarlar çıkarılır ve eşiklenerek belirlenen alanlarda simetrier bulunur. Simetriye sahip yatay ve dikey kenarların bulunduğu bölge görüntü içerisinde arama alanı olarak belirlenmektedir. Bu arama alanı içerisinde perspektif ve boyut kısıtlamaları gözetilerek araca ait simetrik alt kenar ve üst kenar noktaları belirlenmektedir. Daha sonra tahmini araç bölgeleri sınırlayıcı dikdörtgen ile belirlenmektedir. Öndeki araca ait mesafe tahmini, stereo kamera görüntülerinde belirlenmiş olan araç bölgesini gösteren dikdörtgenlerin iki görüntüdeki piksel konum bilgilerinin farkına dayalı olarak yapılmaktadır. İki kameranın bilinen kalibrasyon bilgileri de kullanılarak oluşturulan üçgenleme modeliyle mesafe tahmini değeri hesaplanmaktadır. Araç algılama işleminin sadece görüntünün azaltılmış bir bölümünde yapılmış olmasının stereo kameralar ile yapılan iki görüntünün karşılaştırılmasına dayalı görüntü işleme yöntemlerinin getirdiği hesaplama karmaşıklığının azaltılmasını sağladığı ifade edilmektedir. Çalışmanın sonuçlarını göstermek üzere farklı ortamlarda algılanan araçların araç arama alanları ile araç bölgelerini gösteren dikdörtgenlerin bulunduğu 9 görüntü örneği sunulmaktadır. Mesafe tahmini sonuçlarına ait herhangi bir istatistiksel veri bulunmamaktadır.

Nedevschi ve ark. (2004); yapmış oldukları stereo görmeye dayalı çalışmayla araç sürüşü için farklı tipteki yollara ait çeşitli trafik senaryolarında çevresel ortamda bulunan engellerin tespitini ve uzaklıklarının tahminini gerçekleştiren yöntem ve teknikleri sunmuşlardır. Öncelikle sol ve sağ kameradan elde edilen görüntülere kenar belirleme dedektörü uygulanarak görüntülerdeki kenar bölgeleri belirlenmektedir. Belirlenmiş olan iki görüntüdeki kenar bölgeleri eşleşmesine göre benzeşen nokta çiftlerinin, kameraların kalibrasyonu ile belirlenen bir stereo geometrisi kullanılarak üç boyutlu koordinatları belirlenmektedir. Kameraların kalibrasyonu sonrasında hızlanma, yavaşlama ve direksiyon gibi dinamik faktörler aracın yer yüzeyine göre eğimini ve dönüş açılarını değiştirmesine neden olur. Bu açılar elde etmek için şasi ve tekerlek

kolları arasına dört sensör yerleştirilmiştir. Bir ilgi alanı bölgesi oluşturularak yol bölgesinde daha önce belirlenmiş olan kenar bölgelerine ait noktalar yoğunluk değerlerine göre gruplandırılmaktadır. Üç boyutlu koordinatları bilinen bu nokta grupları görüntü içerisinde küboidlerle temsil edilmektedir. Bu şekilde yol üzerindeki nesnelerin belirlenmesi sağlanmaktadır. Doğrusal bir Kalman filtresi, video görüntülerinde yer alan nesnelerin konum değişimleri ve hızlarının değerlendirilmesi için kullanılmaktadır. Mesafe tahmini üç koordinat eksenini boyunca yer değiştirmelere farklı ağırlıklar veren ve nesne hızını da dikkate alan bir denklem ile belirlenmiştir. İzlenen nesnelerin değerlendirmesi bir video görüntü dizisinden saniyede 10 kare yakalayan bir sistem kullanılarak yapılmıştır. Mesafe tahmini değerlendirmelerinin 90 metreye kadar yapılabildiği, 10 metre ile 60 metre arasındaki değerlendirmelerin maksimum güvenilirliğe sahip olduğu ifade edilmiştir. Mesafe tahminine ait değerlendirmeler için yapılan denemelerin; 10 metre için yaklaşık 10 cm, 45 metre için yaklaşık 30 cm ve 90 metre için yaklaşık 2 metre hata içerdiği belirtilmiştir.

Toulminet ve ark. (2006); bir stereo görüş sistemiyle öndeki aracın algılanmasını ve mesafesinin tahminini sağlayan bir çalışma sunmuşlardır. Çalışmada öncelikle üç boyutlu özellikleri yakalamak için dikey nesnelere ait olan özellikleri yol ve arka plan özelliklerinden ayıran stereo görüş tabanlı bir algoritma uygulanmaktadır. Belirlenen bu üç boyutlu dikey özellikler, bir simetri operatörü kullanılarak basit bir araç modeliyle eşleşme yapan monoküler görüş tabanlı bir yaklaşımla öndeki aracın tespitinin yapılmasına yardımcı olur. Potansiyel engellere ait olmayan, yol veya diğer bölgelere ait özellikler filtrelenerek öndeki aracın algılanması ve mesafe tahmini hesaplaması yalnızca üç boyutlu dikey nesnelere temsil eden kenarlar dikkate alınarak yapılmaktadır. Belirlenen aracın mesafesinin tahmini için çıkarılan üç boyutlu bilgilerden faydalanılmaktadır. İki optik merkez arasındaki mesafe, CCD (Charge Coupled Device) pikselinin genişliği ve iki merceğin odak uzaklığı değerleri yapılan hesaplamalarda kullanılmaktadır. Yapılan tahminlerin değerlendirmesine yönelik araç algılama ve mesafe tahmini yapıldığı görülen görüntü örneklerinde, karmaşık arka plana sahip görüntülerde araç algılamada hataların olabileceği görülmektedir. Ayrıca önerilen yöntemin tek bir araç algılama yapabildiği ancak algılanan aracın her zaman en yakın araç olamayabileceği görülmektedir. Yapılan mesafe tahminlerinin başlangıç ve bitiş değerleri belirlenen bir sayı aralığı kullanılarak yapıldığı görülmektedir.

Huh ve ark. (2008); yapmış oldukları çalışmayla bir aracın üzerine yerleştirilmiş iki kameradan karayolunda seyir halindeyken elde edilen stereo görüntüleri kullanarak aynı şeritte bulunan engellerin tespitini sağlayan ve araca olan mesafelerini tahmin eden yöntem ve teknikleri sunmuşlardır. İşlem yükünü azaltmak için; engel tespiti, şerit bilgisine dayalı ilgi alanı seçilerek yapılmaktadır. Engel tespiti; stereo görüntüler kullanılarak yapılan özellik eşleştirme, epipolar kısıtlamalar ve özellik birleştirme yöntemleriyle gerçekleştirilir. Görüntülerden tespit edilen köşe bilgisi özellikleri stereo görüntü eşleştirme için kullanılır. Stereo eşleştirme sonuçları uygun karşılık çiftlerini belirlemede kullanılır. Tespit edilen engeller için bir izleme algoritması kullanılmaktadır. Araç ile tespit edilen engeller arası mesafe tahmini engellere ait konum bilgilerini kullanan bir üçgenleme yöntemi ile yapılmaktadır. Önerilen yöntemin sonuçlarını değerlendirmek için 10 metre ile 65 metre arasında 5 metre aralıklarla alınan görüntü örnekleri kullanılmıştır. Yapılan değerlendirmede önerilen yöntemin 45 metre için yapmış olduğu mesafe tahmininin %5 hata içerdiği ifade edilmiştir. Mesafe arttıkça ölçüm hata oranının arttığı; 70 metre ve üzerinde yapılan değerlendirmelerin büyük hata oranları içerdiği ifade edilmektedir.

Lim ve ark. (2008); stereo görüş sistemine dayalı bir mesafe ölçüm yöntemi ile öndeki aracın kısa ve uzun mesafeler için uzaklığını hesaplayan bir çalışma sunmuşlardır. Çalışmalarında, iki kamera arasındaki eşitsizliğe dayalı yöntemin doğruluğunu artırmak için düzenlenmiş bir alt piksel yer değiştirme yöntemi ile kamera sensöründen kaynaklanan hataları azaltmak için güçlü bir izleme Kalman filtresinden oluşan bir algoritma kullanmışlardır. Belirtilen yöntemde; piksel sayısına bağlı eşitsizliklerde uzak mesafelerde yapılan ölçümlerdeki piksel sayısında azalmadan kaynaklanan hata oranını azaltmak için alt piksel yer değiştirme algoritmasıyla örnekleme hataları azaltılmıştır. Asimetrik parabol uydurma yöntemiyle benzerlik fonksiyonunun simetrik bir parabol şekline sahip olduğu varsayılmakta ve fonksiyonun minimum noktası bulunarak doğru bir eşitsizlik tahmini yapılabilmektedir. Son olarak ölçüm, uygulanan Kalman filtresiyle nesnenin hareketine ve mesafesine uyarlanarak harici ortamdan kaynaklı değişikliklere duyarlı hale getirilmiştir. Belirlenen yöntemin performansını değerlendirmek üzere uygulamış oldukları bir simülasyon ile hedef aracın manevra yapması ve doğrusal olmayan hareketlerde bulunması gibi durumlar da gözetilerek yüzlerce metreye kadar ölçüm gerçekleştirebildiği ifade edilmiştir. 30 sn için 30 ms örnekleme oranı ile yapılan

simülasyon değerlendirme sonuçlarına göre 400 metreye kadar olan ölçümlerde RMSE (Root Mean Square Error) değerinin yaklaşık 0.04 olduğu belirtilmiştir.

Kormann ve ark. (2010); stereo vizyon ile gerçek zamanlı olarak; oluşturulan bir aykırılık haritasından elde edilen 3d verilerle araçları algılayan ve algılanan araçların mesafesini tahmin eden yöntemleri sunmuşlardır. Çalışmada eğim değişikliklerinden hareketle belirlenen yol modeli, araç algılaması için arama bölgesinin azaltılmasını sağlamaktadır. Mesafe tahmini, oluşturulan aykırılık haritası üzerinden küboid olarak işaretlenen araçların alan derinliği kullanılarak yapılmaktadır. Önerilen yöntem bir GPS (Global Positioning System) sistemi kullanılarak gerçek trafik sahneleri üzerinden değerlendirilmektedir. Değerlendirmelerde 30 metreye kadar araç tanıma işleminin gerçekleştirilebildiği belirtilmiştir.

Hou ve ark. (2011); güvenli sürüş mesafesinin ölçülmesine yönelik yapmış oldukları çalışmada, geleneksel kamera kalibrasyon yöntemi kullanarak oluşturdukları stereo kamera görüntüleme modelini kullanmışlardır. Ardından sol kamera görüntüsü ile sağ kamera görüntüsü arasında bir açılma noktasına karşılık gelen eşleme yapılarak, oluşturulan geometrik model vasıtasıyla hedef araç ile kamera arasındaki mesafe hesaplanmıştır. Oluşturulan geometrik model üçgen teorisine dayanır. Aynı seviyedeki iki kamera ile hedef nesnelere bir üçgen oluşturur. Kamera kalibrasyonu ve eşleme algoritmaları, iki kamera konumu arasındaki ilişki kullanılarak incelendiğinde hedef nesnenin görünümünde özellik noktalarının 3d bilgisi, yani uzaysal koordinatlar elde edilir. Uygulanan yöntemin test edilmesi için 10 m, 15 m, 20m ve 50 m'lik dört mesafe belirlenmiştir. Belirlenen bu dört mesafe için beşer örnek alınarak, toplam 20 örnek üzerinden uygulanan yöntemin değerlendirmesi yapılmaktadır. Hesaplanan araç mesafeleri ile gerçek araç mesafeleri karşılaştırılarak hata yüzdeleri belirlenmiştir. Araç mesafesi 15 metrenin altında olduğunda hesaplanan bazı değerler için hata oranının %0.5'in altında olduğu belirtilmiştir. Araç mesafeleri arttığında hassasiyet ve bozulmalardaki artış nedeniyle hata oranlarının arttığı belirtilmiştir. Araç mesafesi 20 m ve üzerinde olduğunda elde edilen en iyi hata oranının %0.9'a kadar ulaştığı ifade edilmiştir. Çalışmada sunulan, yapılan tüm testlerin hata oranlarının yer aldığı tabloya göre hata oranlarının %0.31 ile %3.51 arasında değişen değerler almakta olduğu

görülmektedir. Görüntülerde meydana gelen gürültünün hataya neden olduğu ve hesaplama hassasiyetini etkilediği belirtilmiştir.

Leu ve ark. (2011); yapmış oldukları çalışmada otomotiv uygulamaları için sensör olarak stereo kamera kullanan bir çarpışma uyarı sistemi sunmuşlardır. Çalışmada, stereo kameralardan elde edilen görüntü çifti ile bir blok eşleştirme algoritması kullanılarak aykırılık haritası çıkarılmaktadır. Bir bağlantılı piksel etiketleme yöntemi kullanılarak ortaya çıkarılan aykırılık haritasının bölümlere ayrılma işlemi yapılmaktadır. Son olarak bölümlere ayrılmış nesnelere araca tehlikeli yakınlıkta olanları uyarı sistemiyle bildirilmektedir. Stereo kamera parametreleriyle birlikte kameraların projeksiyonlarının iki görüntüdeki bilinen konumları vasıtasıyla görüntüler üzerindeki noktaların 3d konumları alınmaktadır. Bunun için aykırılık haritalarından yararlanır. Aykırılık haritalarının oluşturulması stereo görüntülerdeki karşılık gelen noktaların koordinatlarındaki farklılıkların hesaplanmasına dayanır. Hesaplanan eşitsizlik değerleri görüntülenen sahnedeki noktanın 3d konumunun elde edilmesinde kullanılır. Üçüncü boyut derinliğinin hesaplanması için kameranın odak uzaklığı ve stereo kamera merkezleri arasındaki mesafeyi temsil eden taban çizgisi kullanılır. Aykırılık haritaları; üzerlerinde bulunan daha parlak piksellerin kameraya daha yakın nesnelere ait olduğu ve daha koyu piksellerin ise kameraya daha uzak nesnelere ait olduğu gri tonlamalı görüntülerdir. Bu gri tonlamalı görüntüler; aykırılık haritalarında bulunan piksellerin sahip olduğu, stereo görüntülerde yer alan aynı koordinatlardaki pikseller için sağlanan eşitsizlik değerleri ile meydana getirilir. 8-30 m aralığı için yapılan değerlendirmede mesafe belirlenmesinde beklenen hata oranının %5 değerinin altında olduğu ifade edilmiştir.

Seo ve ark. (2013); çok yönlü stereo görüşe dayalı bir sürücü destek sistemi ile sürücüye öndeki araç ile olan mesafesi hakkında bilgilendirme sağlamışlardır. Çalışmada kullanmış oldukları hiperbolik aynalı çok yönlü kameralar geleneksel perspektif kameralardan farklı olarak 360 derece görüşe sahiptir. Bu şekilde şüruh aracının etrafındaki yol koşullarına ait detaylı bilgiler elde edilmektedir. Öndeki aracın tespit edilmesi için HOG (Histogram of Oriented Gradients) tekniği kullanılmıştır. HOG ile görüntüde yer alan belirli bir bölgedeki parlaklık dağılımının histogramına sahip özellikler tanımlanmaktadır. Tanımlanan bu özellikler nesne şeklinin temsili olmaktadır.

Histogramla temsil edilen, görüntüdeki yerel alanda bulunan komşu piksellerin dağılımıdır. Araç algılandıktan sonra öndeki aracın 3d konumu ve mesafesini belirlemek için çok yönlü görüşü kalibre edebilen bir kamera kalibrasyon yöntemi uygulanmıştır. Bu yöntemle dünya koordinat sistemini stereo kamera için kamera koordinat sistemine bağlayan bir denklem elde edilmiştir. Çalışmada yapılan deneylerde öndeki araç algılama oranının tespiti amacıyla her bir kameradan alınan video görüntülerinden elde edilen 2701'er adet görüntü kullanılmaktadır. Araç algılama oranının; sol kamera için %99.78 ve sağ kamera için %94.59 olduğu ifade edilmiştir. Mesafe ölçümüne yönelik yapılan doğrulama ve kamera kalibrasyonu için çok yönlü stereo kameranın bir satranç tahtasından 8 m uzaklığa kadar olan farklı konumlarından alınan görüntüleri kullanılmaktadır. Satranç tahtasındaki her köşe, doğruluğu artırmak üzere kamera kalibrasyonu için kullanılmaktadır. Satranç tahtasından 8 m uzaklığa kadar olan 15 örnek görüntüyle yapılan mesafe tahminine ait maksimum ve minimum hatalar sırasıyla 244.97 mm ve 27.76 mm olarak belirtilmektedir.

Katada ve ark. (2014); üçgenleme modeline dayalı bir nesne uzaklığı belirleme yöntemini kullanarak, optik eksenleri birbirine paralel ve optik eksenleri aynı oranda birbirine doğru eğimli stereo kamera modellerini karşılaştırmaktadır. Yapmış olduğu denemelerin sonuçlara dayanarak optik eksenleri aynı oranda birbirine doğru eğimli stereo kamera modelinin optik eksenleri paralel stereo kamera modeline göre daha başarılı olduğunu ifade etmektedir.

Li ve ark. (2016); paralaks binoküler kamera modeli ile elde edilen görüntüler kullanılarak karayolunda öndeki araç ile olan mesafe ölçümünü sağlayan bir yöntem sunmuşlardır. Kamera kalibrasyonu ile görüntüler içerisinde yer alan araç bölgesine ait özellik noktası algılama ve eşleştirme yöntemleri kullanılmaktadır. İki kamera ile elde edilen aynı araca ait görüntüler kullanılarak Harris köşe çıkarma algoritması ve gri skala dağılımına dayalı eşleştirme yöntemi ile tespit edilen belirli noktalara ait koordinatlar elde edilmektedir. Paralaks ilkesi ile aracın özellik noktasının üç boyutlu geometrik bilgilerinden yararlanılarak araçlar arasındaki mesafe belirlenmektedir. Sabit mesafede bulunan bir araca ait sağ ve sol kamera görüntülerinden eşleştirilen 5 farklı köşe noktası için 5 mesafe tahmini yapılmaktadır. Öndeki aracın uzaklığı 2.45 m olarak

belirlenmiştir. Yapılan mesafe tahmini hata oranlarının maksimum ve minimum değerleri sırasıyla, %0.64 ve %0.05 olarak bildirilmektedir.

Lim ve ark. (2017); stereo kamera sisteminden elde ettiği görüntüleri kullanarak araç algılama ve mesafe tahmini yapabilen yöntemleri içeren bir sistem sunmuşlardır. Çalışmada iki kameradan elde edilen görüntülere uygulanan bir eşitsizlik çıkarma algoritması, nesne algılama ve mesafe tahmini için kullanılmıştır. Bu aşamadan sonra nesne algılama için, nesnelere ait aday bölgelerin belirlenmesi ve sınıflandırılması aşamaları uygulanmaktadır. Nesne aday bölgelerinin belirlenmesi için görüntü eşitsizliğinden çıkarılan ve nesnelere özgü dikdörtgenlerin nesnelere yerini belirlediği stixels kullanılmaktadır. Belirlenen her stixels nesnelere yakınlığına göre farklı renklerden oluşmaktadır. Tespit edilen stixels bölgelerinin ön plan ve arka plan olarak sınıflandırılması için bir CNN (Convolutional Neural Network) tabanlı bir sınıflandırıcı kullanılmaktadır. Mesafe tahmini görüntü eşitsizliği ile kamera parametreleri arasındaki bağıntı kullanılarak yapılmıştır. CNN sınıflandırıcısıda kullanılmak üzere eğitim seti için 3712 ve doğrulama seti için 3769 görüntü örneği kullanıldığı ifade edilmektedir. Yapılan değerlendirme sonucunda CNN sınıflandırıcısı ile gerçekleştirilen araç algılama işleminin %91.14 doğruluk oranı elde ettiği belirtilmektedir. Mesafe tahminine yönelik yapılan değerlendirmede; 5 m altındaki değerlendirmeler için %8.33, 5 m üstündeki değerlendirmeler için %7.49 hata oranı elde edildiği ifade edilmektedir.

Salman ve ark. (2017); yapmış oldukları çalışmada yatay taban üzerine sabit bir aralık ile konumlandırılan ve optik eksenleri birbirine paralel olan iki kameradan elde edilen görüntülerden mesafe tespiti yapabilen bir yöntem sunmuşlardır. Sağ ve sol kamera görüntüleri için hedef nesnenin x eksenindeki koordinatları arasındaki farkı ile kamera lensleri arasındaki mesafe ve kamera görüntü alma açılarından yararlanılarak oluşturulan denklem ile mesafe tahmini yapılmaktadır. Çalışmayla önerilen mesafe tahmin yönteminin performansını değerlendirmek üzere hedef nesne olarak belirlenen bir beysbol topunun 8.5 m'den 160 m'ye kadar olan 7 farklı uzaklığından alınan görüntü örnekleri kullanılmaktadır. Elde edilen deneysel sonuçların 20 m'ye kadar hassasiyeti yüksek sonuçlar verdiği ifade edilmektedir. 7 deneye ait ortalama hata oranının %2.13 olduğu belirtilmektedir.

Yoo ve Seo (2017); stereo kamera sistemi ile alınan görüntülerin analizinden elde edilen temel bilgileri kullanarak frekans-etki alanı analizi yoluyla doğru mesafe ölçümleri sağlamak için bir yöntem sunmuşlardır. Yöntemde ilk olarak ufuk noktası belirlenerek önışleme aşamasında ilgilenilen görüntü bölgesi azaltılmaktadır. Ufuk noktasının belirlenmesi için Canny kenar belirleme algoritması ile aracın sağında ve solunda bulunan yol şerit çizgileri tespit edilerek kesişim noktaları elde edilmektedir. Daha sonra frekans alanında verilen görüntüler işlenerek her bir frekans bileşeni değerinin eşitsizlik haritalarında ne derece ilişkili olduğu kontrol edilmektedir. Frekans alanında görüntü, bir Fourier dönüşümü yoluyla temel fonksiyonların bir kombinasyonları ile temsil edilmektedir. Frekans bileşeni görüntüdeki parlaklık derecesini göstermektedir. Araç ortamındaki frekans alanındaki görüntünün düşük frekanslı bilgileri içeren kısmı yol alanını, yüksek frekanslı bilgilere sahip bölgeleri ise ön planı içeren alanları belirlemektedir. Son olarak hedef nesnenin uzaklığı; iki kamera arasındaki taban çizgisi, odak uzaklığı ve pikseller arası eşitsizlik kullanılarak belirlenmektedir. İki görüntü arasındaki aydınlatma farkının mesafe tahminine olan olumsuz etkisini azaltmak amacıyla NCC (Normalized Cross Correlation) yöntemi kullanılırken, oklüzyon/süreksizlik etkisini azaltmak için yüksek geçişli bir filtre uygulanarak nesne alanı vurgulanmaktadır. Çalışmada önerilen yöntemin değerlendirilmesine yönelik kentsel yol, otoyol ve tünel yolu üzerinde stereo kamera ile çekilen video klipleri kullanılarak testler yapılmıştır. Yapılan denemelerde önerilen yönteme ait mesafe tahmini sonuçları, araç üzerine monte edilen bir LIDAR sistemi ile elde edilen sonuçlar dikkate alınarak değerlendirilmektedir. Ayrıca elde edilen sonuçlar SGM (Semi Global Matching) olarak adlandırılan geleneksel bir mesafe tahmini yöntemi ile karşılaştırılmaktadır. Önerilen yöntemin 5-10 m arasındaki tahmin sonuçlarının %0.7 hata oranı ortalamasına, 30-35 m arasındaki tahmin sonuçlarının %2.9 hata oranına sahip olduğu ve hata oranlarının mesafe arttıkça artış gösterdiği belirtilmektedir. Mesafe arttıkça, nesnelere ait renk bilgisindeki azalma, piksel sayısındaki azalmadan ve mesafenin kullanılan eşitliğe ters orantılı olmasından dolayı tahmin sonuçlarına ait hata oranının da arttığı belirtilmektedir. Önerilen yönteme ait sonuçların geleneksel SGM yöntemine göre yaklaşık olarak ortalama %10 daha iyi sonuç verdiği ifade edilmektedir.

Irmisch (2017); AprilTag ve WhyCon işaretçileri kullanarak mesafeleri Perspektif-n Noktası, bir dairenin 3d konum hesaplaması ve stereo tabanlı üçgenleme yöntemleri ile

hesaplayan bir çalışma sunmuştur. Mesafe tahmin doğruluğu ve uygulanabilirlik aralığına göre yapılan değerlendirmeyle belirlenen yöntemler birbirleriyle ve geleneksel SGM yöntemiyle karşılaştırılmaktadır. Belirtilen tekniklerin karşılaştırılması simülasyon verileri ve gerçek dünyadan elde edilen verilere dayalı olarak yapılmaktadır. Uygulanan bir simülasyona dayalı veriler ile görüntü verilerinin çeşitliliği sağlanmış ve yöntemlerin belirsizliklerinin geometrik kamera kalibrasyonu parametreleriyle uyumunun modellenmesi gerçekleştirilmiştir. Sunulan yöntem ile mesafe tahmini için işaretçilerin kullanılmasının geleneksel stereo eşleştirme yöntemlerinde kullanılan kamera kalibrasyonundaki belirsizliklere karşı düşük hassasiyet sağlanarak yüksek doğruluk oranları elde edildiği belirtilmektedir.

Ashoori ve Mahlouji (2017); yapmış oldukları çalışmada bir kamerasını y eksenini etrafında döndürerek kameraların optik eksenlerinin kesişmesini sağladıkları bir stereo kamera düzeneği ile araçlar arası mesafeyi tahmin etmek için gerekli stereo görme sürecini ele almışlardır. Çalışmada; kameralardan elde edilen görüntülerdeki bozulmaları düzeltme, görüntü yumuşatma, stereo görüntü eşleştirme ve son olarak mesafeyi hesaplamak için gerekli hesaplama teknikleri sunulmaktadır. Öncelikle bir dama tahtasının sabit bir mesafeden elde edilen farklı açısal konumlarına ait görüntüleri kullanılarak kameraların kalibrasyonu yapılmaktadır. İki kameradan elde edilen görüntülerden öndeki araca ait plaka bölgesi tespit edildikten sonra bu bölgelere ait merkez noktalarının kamera koordinat sistemindeki konumları belirlenmektedir. Daha stereo kamera üçgenleme modeli ile elde edilen denklem kullanılarak mesafe bilgisi hesaplanmaktadır. Mesafe tahmin yönteminin değerlendirilmesi için 1.5 m uzaklıkta bulunan bir aracın, farklı aydınlatma koşullarındaki ve kamera düzeneğinin farklı yatay pozisyonlarındaki 5 farklı zamanda alınan toplam 35 görüntü örneği kullanılmaktadır. Yapılan denemelerde elde edilen sonuçların %89.9 doğruluk oranına sahip olduğu belirtilmektedir.

Tram ve Yoo (2018); LED (Light Emitting Diode) tabanlı VLC (Visible Light Communication) teknolojisini kullanarak, bir aracın arka farına yerleştirdiği bir LED'in stereo kamera düzeneği ile elde edilen düşük çözünürlüğe sahip görüntülerinden aracın mesafesini tahmin edebilen bir yöntem sunmuşlardır. Stereo kamera düzeneği öndeki aracın LED'ini yakalamak için bir araca monte edilerek elde edilen görüntülerden iki

araç arasındaki mesafe tahmin edilmektedir. LED'in yüksek aydınlatmasının ve kompakt şeklinin elde edilen görüntülerde LED'in algılanmasını kolaylaştırdığı ifade edilmektedir. Bu sayede mesafe tahmininde kullanılan piksel koordinatlarını belirleme işleminde düşük çözünürlüklü kameralar kullanılabileceği belirtilmektedir. Çalışmada kamera lensleri arasındaki mesafe bilgisi, kameraların odak uzaklıkları ve LED'in kamera görüntülerindeki koordinat bilgilerinden yararlanılarak oluşturulan iğne deliği kamera geometrik modeli ile mesafe hesaplanmaktadır. Hesaplanan mesafeler Kalman filtresi ve medyan seçim yöntemi ile iyileştirilmektedir. Önerilen yöntemin performansını değerlendirmek amacıyla takip eden araçta bulunan kameralardan alınan LED'in monte edildiği hedef aracın trafik ortamında hareket halindeki görüntüleri kullanılmaktadır. Değerlendirmede, görüntü sensörlerinin farklı çözünürlükleri için farklı mesafelerdeki tahmin sonuçlarına yer verilmiştir. Önerilen yöntemin iki araç arasındaki mesafe uzadığında görüntü sensörünün düşük çözünürlüğün neden olduğu yüksek tahmin hatasını telafi etmede başarılı sonuçlar verdiği belirtilmektedir.

Olaverri-Monreal ve ark. (2018)'nin yapmış olduğu çalışmayla; bir aracın arka camına yerleştirilen birbirine paralel iki kameradan elde edilen görüntülerden elde edilen verilere göre arkadaki araçların takip mesafeleri belirlenerek aracın arka camına yerleştirilen bir uyarı panosu vasıtasıyla arkadan takip eden araçlara tehlike hakkında eş zamanlı bilgi verilmektedir. Bu amaçla karayolu trafiğinde 130 km/h sabit hızla hareket eden iki araçtan faydalanılarak arkadan takip eden aracın eş zamanlı görüntülerinin alındığı ifade edilmektedir. Çalışmada Haar benzeri bir kaskad sınıflandırıcı kullanılarak kameralardan elde edilen görüntülerde araç tespiti yapıldıktan sonra takip eden aracın koordinat bilgilerinden yararlanan stereoskopik görmeye dayalı geleneksel mesafe hesaplama yöntemi ile mesafe tahmini yapılmaktadır. Mesafe tahmininde tespit edilen aracın her iki resimdeki göreceli piksel konum farkı kullanılmaktadır. Sınıflandırıcıda kullanılmak üzere, aracın arka camından görüntüsü alınan 600 aracın ön görüntüsünden ve farklı nesnelere ait 2100 negatif görüntüden yararlanıldığı ifade edilmektedir. Önerilen yöntemin sadece iki aracın tek şeritte birbirini takip ettiği durumlar için geçerli olduğu, otoyollarda veya diğer çok şeritli yollarda araç tespiti için uygun olmadığı ifade edilmektedir. Önerilen yöntemin değerlendirilmesi üç boyutlu sürüş simülatörü içeren simülasyon tabanlı bir sistem ile yapılmaktadır. Değerlendirmede ön araçta bulunan bilgilendirme sistemi ve arka araçta bulunan mesafe

uyarı sistemi karşılaştırılmaktadır. Ön araçta bulunan bilgilendirme sistemi takip mesafesinin ihlal edilmesi durumunda görsel uyarı sağlarken arka araçta bulunan mesafe uyarı sistemi öndeki araçla olan zaman aralığını yansıtmaktadır. Güvenilir takip mesafesi için öndeki araçla olan zaman aralığının minimum 2 sn olması gerektiği ifade edilmektedir. Sürücüye zaman aralığıyla ilgili bulunduğu araçtan bilgilendirme yapmanın dikkat dağıtmaya neden olabileceği ve ön araçta takip mesafesi ile ilgili görsel uyarı sunmanın daha etkili sonuçlar verdiği ifade edilmektedir.

Zaarane ve ark. (2019); aracın ön camına stereoskopik kamera olarak monte edilmiş iki kamera kullanarak görüntü işlemeyle dayalı araçtan araca mesafe ölçüm sistemi sunmuşlardır. Mesafe; kameralar arasındaki mesafe, kameraların görüş açısı ve diğer belirli açılar gibi teknik veriler kullanılarak geometrik türevlerden hesaplanmaktadır. Çalışmada ilk olarak, araç tespiti için kameralardan birinde ayrı dalgacık dönüşümüne dayanan bir yöntem kullanıldığı ifade edilmektedir. Önerilen yöntemde, kenar algoritması kullanılarak tek kameraya ait giriş görüntülerinden yatay ve dikey kenarlar çıkarılmaktadır. Elde edilen kenarlar çapraz korelasyon yöntemi ile diğer kamera görüntüsüyle eşleştirilerek görüntülerde yer alan araçların tüm potansiyel konumları üretilmektedir. Daha sonra potansiyel konumları belirlenen araçlar bir AdaBoost sınıflandırıcı ile “taşıt” veya “taşıt değil” olarak doğrulanmaktadır. Son olarak her iki görüntüdeki araçların yatay merkez noktalarının hesaplanarak öndeki araçlara ait mesafelerin önerilen mesafe tahmin yöntemiyle belirlendiği ifade edilmektedir. Önerilen sistemi test etmek için iki kamera arasındaki mesafeler değiştirilerek bir araç otoparkından farklı sahnelere ait görüntüler kullanılmaktadır. Bu şekilde kameralar arasındaki mesafeyi değiştirirken araç mesafe ölçümlerinin doğruluğunun test edildiği ifade edilmektedir. Öndeki aracın 5.2 m’den 22.7 m’ye kadar olan 9 farklı mesafesinden denemeler yapılmıştır. Yapılan denemelerde iki kamera arasındaki uzaklığın 0.1 m ile 0.8 m arasındaki ölçüleri denenmektedir. Yapılan bu denemelerde iki kamera arasındaki mesafe 0.6 m olduğunda minimum hata oranına ulaşıldığı ifade edilmektedir. Mesafe ölçüm hatalarının iki kamera arasındaki mesafeye ve dolaylı olarak araç algılama algoritmasının kalitesine dayandığı belirtilmektedir.

### 2.3.3 Çalışmanın literatürdeki yeri

Bu çalışmada, optik eksenleri birbirine doğru eğimli ve birbirini kesen kamera stilinden elde edilen görüntülerden yararlanarak bir araçtan araca mesafe tahmin yöntemi geliştirilmiştir. Literatürde yer alan daha önceki çalışmalarda mesafe tahmini için kullanılan geleneksel kamera modelinde optik eksenleri birbirine paralel kameralar kullanılmıştır. Katada ve ark. (2014); geleneksel kamera modeli ile optik eksenleri birbirine doğru aynı oranda eğimli ve birbirini kesen kamera modelinden elde ettikleri sonuçları karşılaştırmaktadır. Karşılaştırmada iki kamera modeli ile elde edilen görüntülerden geleneksel üçgenleme yöntemi ile elde edilen mesafe tahmin sonuçları kullanılmaktadır. Elde edilen sonuçlara göre, optik eksenleri birbirine doğru aynı oranda eğimli ve birbirini kesen kamera modelinin optik eksenleri birbirine paralel olan geleneksel kamera modeline göre daha başarılı olduğu ifade edilmektedir. Bu çalışmada optik eksenleri birbirine doğru aynı oranda eğimli ve birbirini kesen kamera stili kullanılırken aynı zamanda önerilen kamera stilinin incelenmesi gerçekleştirilerek avantajları ve dezavantajları değerlendirilmiştir.


Bu çalışmada araçtan araca mesafe tahmini için, önerilen optik eksenleri birbirine doğru aynı oranda eğimli ve birbirini kesen kamera stiline uygun bir YSA modeli geliştirilmiştir. Literatürde yer alan daha önceki çalışmalarda kullanılan geleneksel üçgenleme yönteminde görüntülere ait noktaların yatay eksen konum farklılıklarından yararlanılmakta, dikey eksen konum farklılıkları dikkate alınmamaktadır. Çalışmada YSA modeli ile yapılan denemelerde, hedef araca ait bir hedef noktanın kameraların görüntülerindeki yatay eksen değerlerine ait bilgilerinden ve dikey eksen değerlerine ait bilgilerinden hangilerinin mesafe tahmininde etkili oldukları araştırılmıştır.

### 3. MATERYAL ve YÖNTEM

Çalışmada kameraların optik eksenlerinin birbirine doğru eşit oranda eğimli olduğu bir stereo kamera modeli kullanarak ve geliştirilen bir YSA modeli ile araçtan araca mesafe tahmin yöntemi sunulmaktadır. Öndeki aracın belirlenen bir hedef noktasının kamera görüntülerindeki koordinat bilgilerinden yararlanılarak YSA modelinin aday girdi kümeleri belirlenmektedir. Geliştirilen YSA modeli en uygun girdi kümelerini kullanarak öndeki aracın mesafe tahminine ait çıktıyı sunar.

#### 3.1 Önerilen Stereo Kamera Modeli

Şekil 3.1’de; önerilen kamera modelinde, hedef noktanın görüntü içindeki yatay eksen piksel konumlarını sol ve sağ kamera için ifade eden geometrik çizim bulunmaktadır. Öndeki aracın hedef noktası olarak plaka bölgesi merkez noktası seçilmiştir.



Şekil 3.1. Hedef noktaların kameraların perspektiflerindeki konumları

Şekil 3.1’de hedef noktanın sola ve sağa doğru yatay kaymaları  $D_+$  ve  $D_-$  olarak gösterilmiştir.  $D_L$ , sol kameranın hedef noktanın yer aldığı görüntü düzlemine olan optik eksen uzaklığı;  $D_R$ , sağ kameranın hedef noktanın yer aldığı görüntü düzlemine olan optik eksen uzaklığıdır.  $\alpha$ , kameraların görüş açısıdır ve bu açı değeri önerilen kamera modelinde iki kamera için aynıdır.  $\beta$ , kameraların optik eksenlerinin birbirine doğru olan eğim açılarını ifade eder ve bu değer önerilen kamera modelinde iki kamera için de aynıdır.  $D_{lens}$ ; iki kamera lensleri arasındaki uzaklıktır.  $D_{V2V}$ ; kameraların bulunduğu platformun orta noktasının bulunduğu dikey düzlem ile öndeki araç plaka bölgesi orta noktasının bulunduğu dikey düzlem arasındaki mesafeyi tanımlar. Bu değer aynı zamanda iki araç arasındaki mesafenin kalibre edilmemiş ölçüsü olarak kabul edilmektedir. İki araç arası mesafe bu değerden kamera platformunun aracın ön uç kısmına olan uzaklığı çıkarılarak bulunur.

Çalışmada kullanılan kamera modelinde kameraların optik eksenleri, birbirine doğru aynı oranda eğimlidir ve birbiriyle kesişmektedir. Çalışmada önerilen yöntemde mesafe tahmini için YSA kullanılmaktadır. Geliştirilen YSA modeli öndeki aracın hedef noktasının kamera görüntülerindeki koordinatlarından elde edilen bilgileri girdi kümesi olarak kullanılmaktadır. YSA modeli, girdi kümesine göre hedef noktanın iki kamera görüntüsündeki koordinat bilgileri farklılıklarından yararlanarak mesafe tahmini sonucuna ait çıktıyı verir. Hedef noktanın sağa ya da sola doğru yatay sapmalarında kamera platformuyla hedef nokta arasındaki uzaklık değişmemekle birlikte kameraların hedef noktaya olan optik eksen uzaklıkları farklılık göstermektedir. Hedef noktanın sola kayması sağ kamera için optik eksen uzaklığını artırırken sol kameranın optik eksen uzaklığını azaltır. Hedef noktanın sağa kayması sağ kamera için optik eksen uzaklığının azalmasını sağlarken sol kamera optik eksen uzaklığı artmaktadır. Ancak hedef noktanın mesafe bilgisi hedef noktanın sağa veya sola doğru yatay kaymasından etkilenmez. Hedef noktanın sağa veya sola sapmasında kameraların hedef noktalara olan optik eksen uzaklıklarının farklı oranlarda değişmesi hedef noktanın kamera görüntülerindeki koordinatlarına ait yatay eksen değerlerinin farklı oranlarda değişmesini sağlar. Kamera görüntüsünün kapladığı alan kamera görüntü alma açısına bağlı olarak farklı optik eksen uzaklıklarında farklı boyutlarda olur. Kamera görüntülerinde yer alan piksellerin kapladığı alan kameraların görüntü alanına göre değişir. Hedef noktanın sağa veya sola sapma uzaklığı, kamera görüntülerinde farklı

kamera optik eksen uzaklıkları için farklı piksel sayılarına karşılık gelir. Bu durum hedef noktanın kamera görüntülerindeki koordinatlarına ait yatay eksen değerleri arasındaki fark değerinin değişmesine yol açar. Dolayısıyla önerilen yöntemde mesafe tahmini için hedef noktanın kamera görüntülerindeki koordinatlarına ait yatay eksen değerleri arasındaki fark değeriyle birlikte hedef noktanın sağa veya sola doğru yatay sapmalarının dikkate alınması gerekir.

$D_L$ ; sol kamera ile uzaklığı tespit edilecek araç arasındaki mesafeyi ifade etmektedir ve denklemi Eşitlik 3.1'de verilmiştir.  $D$ ; öndeki aracın sola veya sağa kayma uzaklık değerlerini ifade eder. Öndeki aracın sola veya sağa kayması; kameraların bulunduğu görüntü alma platformunun orta noktası dikkate alınarak yapılan hizalamaya göre öndeki aracın plaka bölgesinin merkez noktasının sola veya sağa olan uzaklığı ile belirlenir. Sola kayma durumunda  $D$  değeri pozitif değer alırken, sağa kayma durumunda negatif değer alır.

$$D_L = \left[ \tan(\beta) * \left( \frac{D_{lens}}{2} - D \right) + D_{V2V} \right] * \cos(\beta) \quad (3.1)$$

$D_R$ ; sağ kamera ile uzaklığı tespit edilecek araç arasındaki mesafeyi ifade etmektedir ve denklemi Eşitlik 3.2'de verilmiştir.

$$D_R = \left[ \tan(\beta) * \left( \frac{D_{lens}}{2} + D \right) + D_{V2V} \right] * \cos(\beta) \quad (3.2)$$

Bu formüller sol ve sağ kameralar ile kameraların plaka bölgesi merkez noktasının yer aldığı görüntü alanları arasındaki dik uzaklıkların metre cinsinden değerini bulmak için kullanılır. Bulunan sonuçlar sol ve sağ kameraların o uzaklığa göre görüntü alanları genişliğinin metre cinsinden bulunmasında ve görüntü alanları içerisinde yer alan her bir piksel genişliğinin milimetre cinsinden bulunmasında kullanılır.

Sol kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanı genişliğinin metre cinsinden değeri ( $L_x$ ) Eşitlik 3.3'te verilen denklem ile hesaplanabilir.

$$L_x = \tan\left(\frac{\alpha}{2}\right) * D_L * 2 \quad (3.3)$$

Sağ kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanı genişliğinin metre cinsinden değeri ( $R_x$ ) Eşitlik 3.4'te verilen denklem ile hesaplanabilir.

$$R_x = \tan\left(\frac{\alpha}{2}\right) * D_R * 2 \quad (3.4)$$

Sol kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanında yer alan her bir pikselin genişliğinin mm cinsinden değeri ( $LP_x$ ) Eşitlik 3.5'te verilen denklem ile hesaplanabilir.  $HFOV_{px}$ ; görüntü alanı genişliğinin piksel sayısını ifade etmektedir. Bu değer sabit bir değer olup kameradan elde edilen görüntünün çözünürlüğüne bağlıdır.

$$LP_x = L_x * 1000 / HFOV_{px} \quad (3.5)$$

Sağ kamera için içerisinde plaka bölgesi merkez noktası bulunan görüntü alanında yer alan her bir pikselin genişliğinin mm cinsinden değeri ( $RP_x$ ) Eşitlik 3.6'da verilen denklem ile hesaplanabilir.

$$RP_x = R_x * 1000 / HFOV_{px} \quad (3.6)$$

Sol kamera için görüntü alanı içerisindeki plaka bölgesi merkez noktasının sol kenardan piksel cinsinden uzaklığı ( $AX_1$ ) Eşitlik 3.7'de verilen denklem ile hesaplanabilir.

$$AX_1 = \left[ \left( \frac{D_{lens}}{2} \right) + D_{V2V} * \tan\left(\frac{\alpha}{2} - \beta\right) - D \right] * \frac{\sin(180 - \alpha - \beta)}{\sin \alpha} * \frac{1000}{LP_x} \quad (3.7)$$

Sağ kamera için görüntü alanı içerisindeki plaka bölgesi merkez noktasının sağ kenardan piksel cinsinden uzaklığı ( $BX_2$ ) Eşitlik 3.8'de verilen denklem ile hesaplanabilir.

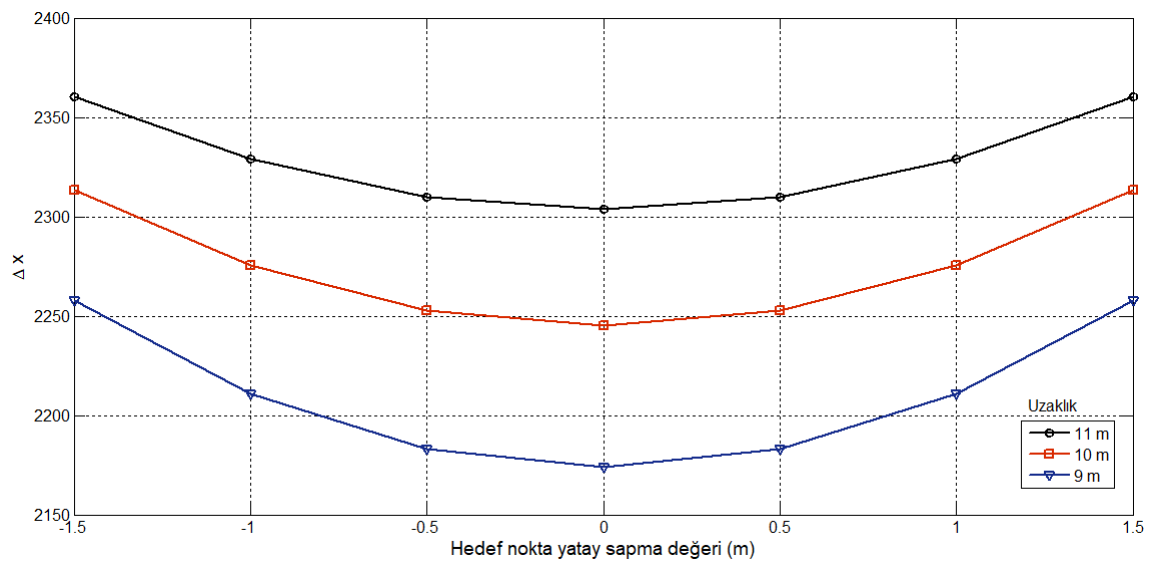
$$BX_2 = \left[ \left( \frac{D_{lens}}{2} \right) + D_{V2V} * \tan\left(\frac{\alpha}{2} - \beta\right) + D \right] * \frac{\sin(180 - \alpha - \beta)}{\sin \alpha} * \frac{1000}{RP_x} \quad (3.8)$$

Sağ kamera görüntü alanı içerisinde yer alan plaka bölgesi merkez noktası ile sol kamera görüntü alanı içerisinde yer alan plaka bölgesi merkez noktasının görüntü koordinatlarının yatay değerleri arasındaki farkın piksel cinsinden değeri ( $\Delta x$ ) Eşitlik 3.9'de verilen denklem ile hesaplanabilir.

$$\Delta x = HFOV_{px} - BX_2 - AX_1 \quad (3.9)$$

Şekil 3.2’de önerilen yöntem için öndeki aracın ardışık olarak 9, 10 ve 11 metre uzaklıklarında, hedef noktanın sağa ve sola sapma değerlerine göre  $\Delta x$  bilgilerini gösteren grafik sunulmaktadır. Kameraların görüntü alma açıları için  $60^\circ$  ve görüntü çözünürlükleri için 4608x3456 piksel değerleri kullanılmıştır. Negatif değerler hedef noktanın sağa sapmasını, pozitif değerler sola sapmasını ifade etmektedir.


Şekil 3.2’de öndeki aracın her sabit uzaklığı için; kamera platformunun bulunduğu araç ile öndeki araç aynı hizada olduğunda başka bir deyişle hedef noktanın yatay sapma değeri 0 m olduğunda  $\Delta x$  değerleri minimum seviyededir. Hedef noktanın yatay sapma değeri arttıkça  $\Delta x$  değeri artarak en yüksek yatay sapma değerinde maksimum seviyeye ulaşır. Hedef noktanın aynı yatay sapma değerleri için öndeki aracın uzaklığı arttıkça  $\Delta x$  değerleri artar. Bu sebeple öndeki aracın farklı uzaklık değerlerine ait  $\Delta x$  değerleri hedef noktanın yatay sapma değerine bağlı olarak birbirlerinden küçük, büyük veya birbirlerine eşit olabilir. Dolayısıyla önerilen kamera modeli için ön aracın mesafe tahminine yönelik bir yöntemde yalnızca  $\Delta x$  değerlerini kullanmak hatalı sonuçlar doğurabilir. Bu yüzden çalışmada kullanılan YSA modeline ait girdi değerleri içinde  $\Delta x$  değerlerinin yanında hedef noktanın kamera görüntüleri içindeki konumlarını ifade eden yatay görüntü koordinat değerleri kullanılmıştır.



Şekil 3.2. Önerilen yöntem için araç kayma miktarına göre  $\Delta x$  değerleri

### Optik eksenleri birbirine paralel stereo kamera modeli


Şekil 3.3’de optik eksenleri birbirlerine paralel olan stereo kamera modeli için sabit uzaklıkta bulunan öndeki aracın sağa veya sola sapma durumuna göre hedef noktanın kameraların görüntü alanlarına ait yatay eksen piksel konumları görülmektedir. Öndeki aracın hedef noktası olarak plaka bölgesi merkez noktası seçilmiştir.  $K_1$ ; hedef noktanın sola sapma durumunu ifade eden konumdur.  $K_2$ ; hedef noktanın kamera platformu orta noktası ile yatay olarak aynı hizada olduğu durumu ifade eden konumdur.  $K_3$ ; hedef noktanın sağa sapma durumunu ifade eden konumdur. Sağ kameranın öndeki araca uzaklığını ifade eden  $D_R$ , sol kameranın öndeki araca uzaklığını ifade eden  $D_L$  ve platform orta noktasının öndeki araca uzaklığını ifade eden  $D_{V2V}$  değerleri birbirine eşittir.  $D_L$  ve  $D_R$  aynı zamanda sırasıyla sol ve sağ kameranın hedef noktalara olan optik eksen uzaklıklarını ifade eder. Bu yöntemde, önerilen optik eksenleri eğimli yöntemden farklı olarak kameraların hedef noktaya olan optik eksen uzaklıkları hedef noktanın sağa veya sola sapmasıyla değişmez. Önerilen kamera modelinden farklı olarak bu modelde öndeki aracın sağa ve sola sapmalarından kaynaklanan iki kamera görüntüsündeki hedef noktanın piksel konumlarının değişimi eşit oranda gerçekleşir. Dolayısıyla bu modelde mesafe tahmini için hedef noktanın yatay sapmalarını dikkate almaya gerek yoktur.



Şekil 3.3. Optik eksenleri paralel kamera modeli

Optik eksenleri birbirine paralel kamera modelinde nesnelerin kamera görüntü alanlarındaki piksel cinsinden kayma miktarları iki kamera için de eşittir. Dolayısıyla öndeki aracın yatay pozisyonundaki değişiminin  $\Delta x$  değerine bir etkisi olmaz. Yani aynı uzaklık değerleri için öndeki aracın kamera görüntüleri içerisindeki bütün farklı yatay konumlarından elde edilen  $\Delta x$  değerleri birbirine eşittir. Bu durumda bu yöntemde önerilen yöntemden farklı olarak öndeki aracın mesafesinin tahmini için  $\Delta x$  bilgisinin yanında hedef noktanın yatay konum bilgisini kullanmaya gerek yoktur.

Şekil 3.4’de paralel kamera yaklaşımı için öndeki aracın ardışık olarak 9, 10 ve 11 metre uzaklıklarında, hedef noktanın sağa ve sola sapma değerlerine göre  $\Delta x$  bilgilerini gösteren grafik sunulmaktadır. Kameraların görüntü alma açıları için  $60^\circ$  ve görüntü çözünürlükleri için  $4608 \times 3456$  piksel değerleri kullanılmıştır. Öndeki aracın her sabit uzaklığındaki hedef noktanın bütün farklı yatay sapma değerleri için  $\Delta x$  değerlerinin birbirine eşit olduğu görülmektedir.



Şekil 3.4. Paralel kameralar için  $\Delta x$  değerleri değişimi

### 3.1.1 Optik eksen eğim açısının etkisi

Çizelge 3.1’de kameraların optik eksen eğim açılarının farklı değerlerinde öndeki aracın ardışık uzaklıklarındaki farklı yatay sapmaları için  $\Delta x$  değerleri yer almaktadır. Ayrıca Çizelge 3.1’de, 9 ve 10 metrelerdeki hedef noktanın aynı yatay sapma değerleri için

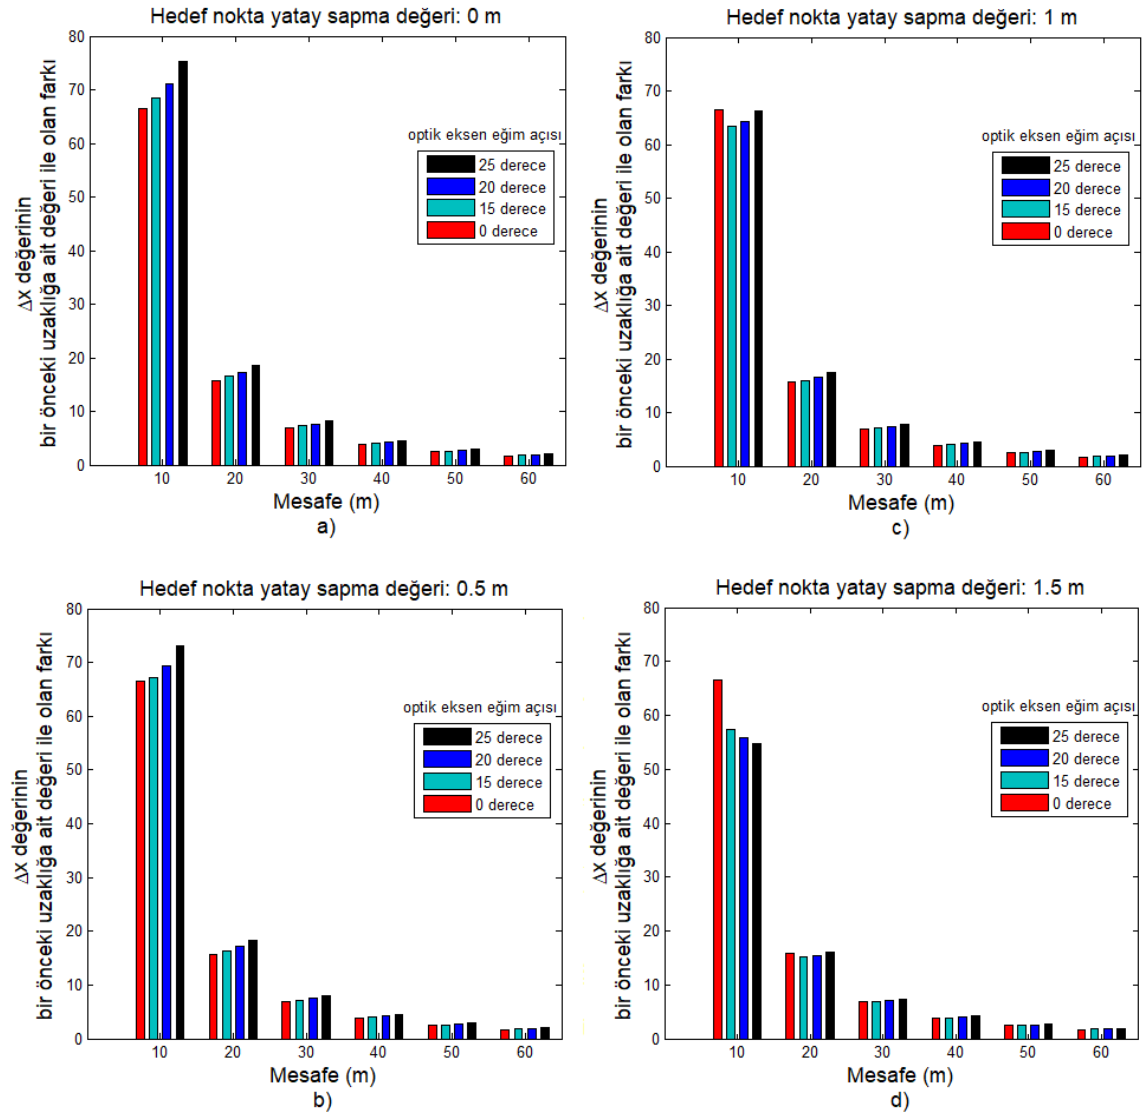
hesaplanan  $\Delta x$  değerleri arasındaki fark bilgileri bulunmaktadır. Bu değerlerdeki artış önerilen yöntem için mesafe tahmininde avantaj sağlamaktadır.  $\Delta x$  değerine dayalı mesafe tahmininde uzaklık değeri değiştikçe  $\Delta x$  değerindeki değişimin büyük olması hata toleransının yüksek olmasını sağlar. Bu  $\Delta x$  değişim değerinin; optik eksenleri eğim açısına sahip kameralarda hedef noktanın yatay sapma miktarı 0 değerine yaklaştıkça yükselerek, 0 değerinde maksimum seviyeye ulaştığı görülmektedir. Hedef noktanın sapma miktarının artması ise  $\Delta x$  değişim değerinin düşmesine sebep olmaktadır.

Çizelge 3.1. Optik eksen eğim açılarına göre 9 ve 10 m’ler için  $\Delta x$  değerleri

15 °						20 °							
$D_{v2v}$	Yatay sapma miktarı	$\Delta X_9$	$D_{v2v}$	Yatay sapma miktarı	$\Delta X_{10}$	$\Delta X_{10}-\Delta X_9$	$D_{v2v}$	Yatay sapma miktarı	$\Delta X_9$	$D_{v2v}$	Yatay sapma miktarı	$\Delta X_{10}$	$\Delta X_{10}-\Delta X_9$
9	-1.75	1522.61	10	-1.75	1575.91	53.31	9	-1.75	2288.16	10	-1.75	2338.36	50.19
	-1.5	1500.99		-1.5	1558.31	57.31		-1.5	2257.75		-1.5	2313.54	55.79
	-1.25	1482.73		-1.25	1543.42	60.70		-1.25	2232.07		-1.25	2292.58	60.51
	-1	1467.80		-1	1531.25	63.46		-1	2211.10		-1	2275.45	64.35
	-0.75	1456.19		-0.75	1521.80	65.60		-0.75	2194.81		-0.75	2262.15	67.34
	-0.5	1447.91		-0.5	1515.04	67.13		-0.5	2183.19		-0.5	2252.66	69.46
	-0.25	1442.95		-0.25	1510.99	68.05		-0.25	2176.23		-0.25	2246.97	70.74
	0	1441.29		0	1509.65	68.36		0	2173.91		0	2245.07	71.16
	0.25	1442.95		0.25	1510.99	68.05		0.25	2176.23		0.25	2246.97	70.74
	0.5	1447.91		0.5	1515.04	67.13		0.5	2183.19		0.5	2252.66	69.46
	0.75	1456.19		0.75	1521.80	65.60		0.75	2194.81		0.75	2262.15	67.34
	1	1467.80		1	1531.25	63.46		1	2211.10		1	2275.45	64.35
	1.25	1482.73		1.25	1543.42	60.70		1.25	2232.07		1.25	2292.58	60.51
	1.5	1500.99		1.5	1558.31	57.31		1.5	2257.75		1.5	2313.54	55.79
	1.75	1522.61		1.75	1575.91	53.31		1.75	2288.16		1.75	2338.36	50.19
	25 °							0 ° (paralel)					
$D_{v2v}$	Yatay sapma miktarı	$\Delta X_9$	$D_{v2v}$	Yatay sapma miktarı	$\Delta X_{10}$	$\Delta X_{10}-\Delta X_9$	$D_{v2v}$	Yatay sapma miktarı	$\Delta X_9$	$D_{v2v}$	Yatay sapma miktarı	$\Delta X_{10}$	$\Delta X_{10}-\Delta X_9$
9	-1.75	3096.26	10	-1.75	3143.55	47.29	9	-1.75	665.11	10	-1.75	598.60	66.51
	-1.5	3055.19		-1.5	3109.98	54.80		-1.5	665.11		-1.5	598.60	66.51
	-1.25	3020.56		-1.25	3081.67	61.11		-1.25	665.11		-1.25	598.60	66.51
	-1	2992.31		-1	3058.56	66.25		-1	665.11		-1	598.60	66.51
	-0.75	2970.40		-0.75	3040.62	70.22		-0.75	665.11		-0.75	598.60	66.51
	-0.5	2954.78		-0.5	3027.83	73.05		-0.5	665.11		-0.5	598.60	66.51
	-0.25	2945.41		-0.25	3020.16	74.75		-0.25	665.11		-0.25	598.60	66.51
	0	2942.29		0	3017.61	75.31		0	665.11		0	598.60	66.51
	0.25	2945.41		0.25	3020.16	74.75		0.25	665.11		0.25	598.60	66.51
	0.5	2954.78		0.5	3027.83	73.05		0.5	665.11		0.5	598.60	66.51
	0.75	2970.40		0.75	3040.62	70.22		0.75	665.11		0.75	598.60	66.51
	1	2992.31		1	3058.56	66.25		1	665.11		1	598.60	66.51
	1.25	3020.56		1.25	3081.67	61.11		1.25	665.11		1.25	598.60	66.51
	1.5	3055.19		1.5	3109.98	54.80		1.5	665.11		1.5	598.60	66.51
	1.75	3096.26		1.75	3143.55	47.29		1.75	665.11		1.75	598.60	66.51

Çizelge 3.1’de yer alan  $\Delta x$  değerlerinin oluşturulmasında, kameraların görüntü alma açıları için  $60^\circ$  ve görüntü çözünürlükleri için  $4608 \times 3456$  piksel değerleri kullanılmıştır. Optik eksen eğim açılarının  $0^\circ$  olduğu paralel kameralarda hedef noktanın yatay sapma değerleri  $\Delta x$  değerini etkilemez. Dolayısıyla kameraların optik eksenleri birbirine paralel olduğunda hedef noktanın ardışık uzaklıklarındaki aynı yatay sapma değerleri için hesaplanan  $\Delta x$  değerleri arasındaki fark değerleri birbirine eşittir.

Şekil 3.5’te hedef noktanın farklı sapma değerleri için oluşturulan grafiklerde kameraların optik eksen eğim açısı değerlerinin mesafe tahminine etkisi görülmektedir.

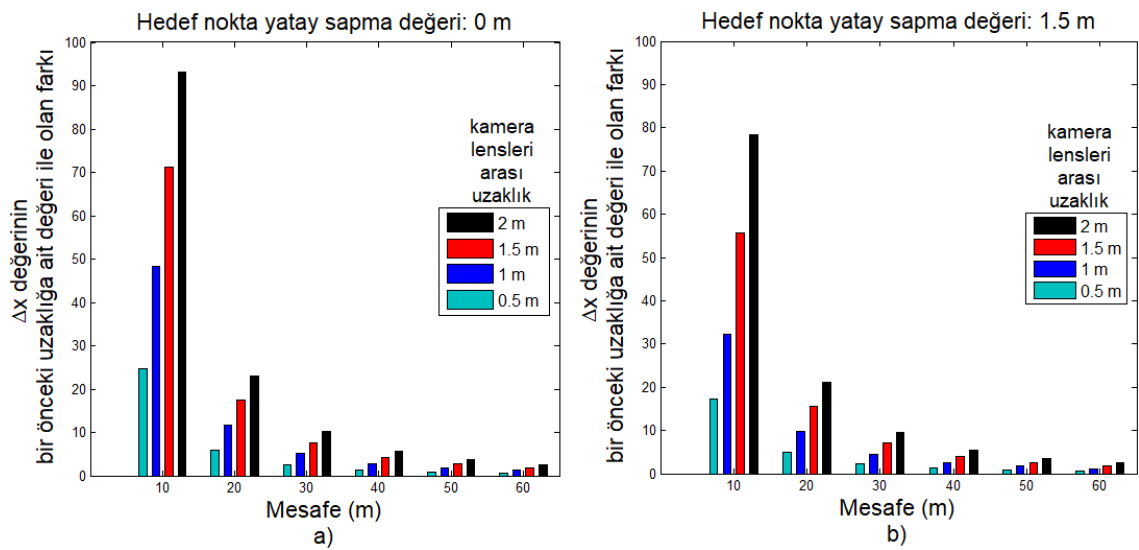


Şekil 3.5. Optik eksen eğim açılarının farklı sapma miktarlarına göre etkisi (a: 0 m sapma değeri, b: 0.5 m sapma değeri, c: 1 m sapma değeri, d: 1.5 m sapma değeri)

Şekil 3.5’te yer alan grafiklerde belirtilen  $0^\circ$  optik eksen eğim açısı, optik eksenleri birbirine paralel stereo kamera modelini temsil eder.  $0^\circ$  olmayan açılara ait bilgiler önerilen optik eksenleri eğimli kamera modeline aittir. Grafikler, yatay eksen üzerinde hedef noktanın uzaklığına ait bilgileri içerir. Dikey eksen üzerinde, yatay eksen üzerinde belirtilen uzaklıklara ait  $\Delta x$  değeri ile yatay eksen üzerinde belirtilen uzaklıktan bir önceki tamsayı uzaklığa ait olan  $\Delta x$  değeri arasındaki farka ait bilgiler yer almaktadır. Bu fark değerinin yüksek olması önerilen yöntemde  $\Delta x$  değerine bağlı olarak yapılan mesafe tahmininde hata toleransının yüksek olmasını sağlar. Şekil 3.5’e göre, önerilen yöntemde hedef noktanın kamera platformu orta noktasından sağa ya da sola doğru 1.5 m değerine kadar olan sapma değerleri için kameraların optik eksenlerinin eğim açılarının yüksek olmasının mesafe tahmininde büyük oranda avantaj sağladığı görülmektedir. Bu avantaj hedef noktanın sapma değerine sahip olmadığı zaman maksimum seviyede iken hedef noktanın sapma değeri arttıkça azalmaktadır.

### 3.1.2 Kamera lensleri arası mesafenin etkisi

Şekil 3.6’da hedef noktanın 0 m ve 1.5 m yatay sapma değerleri için oluşturulan grafiklerde kameraların lensleri arasındaki aralığın önerilen yöntemde mesafe tahminine etkisi görülmektedir.




Şekil 3.6. Farklı yatay sapma değerlerinde lensler arası mesafenin etkisi (a: 0 m sapma değeri ve b: 1.5 m sapma değeri)

Şekil 3.6’da yer alan grafikler, yatay eksen üzerinde hedef noktanın uzaklığına ait bilgileri içerir. Dikey eksen üzerinde, yatay eksen üzerinde belirtilen uzaklıklara ait  $\Delta x$  değeri ile yatay eksen üzerinde belirtilen uzaklıktan bir önceki tamsayı uzaklığa ait olan  $\Delta x$  değeri arasındaki farka ait bilgiler yer almaktadır. Bu fark değerinin yüksek olması önerilen yöntemde  $\Delta x$  değerine bağlı olarak yapılan mesafe tahmininde hata toleransının yüksek olmasını sağlar. Şekil 3.6’da hedef noktanın 0 m sapma değeri ve 1.5 m sapma değeri için oluşturulan her iki grafiğinde kamera lensleri arasındaki uzaklığın artmasının dikey eksen üzerinde belirtilen  $\Delta x$  değerinin bir önceki uzaklığa ait değeri ile olan farkı değerlerini artırdığı görülmektedir. Dolayısıyla önerilen optik eksenleri eğimli stereo kamera modelinde kameraların lensleri arasındaki mesafenin artması mesafe tahmini için avantaj sağlamaktadır.

### 3.2 Sistem Kurulumu


Şekil 3.7’de sistem kurulumunun şematik görünümü yer almaktadır. Çalışmada önerilen yöntemin uygulanması amacıyla bir tavan barının uçlarına kameralar monte edilmiştir. Kameraların optik eksenleri birbirine doğru eşit oranda eğimlidir ve optik eksenler birbiriyle kesişmektedir. Kameraların tavan barının uçlarına monte edilmesiyle elde edilen kamera platformu aracın üzerine yerleştirilmiştir. Yolun aracın bulunduğu zemine paralel eksen ve kameraların bulunduğu platform eksenleri birbirine paraleldir.



Şekil 3.7. Sistem görünümü

### 3.2.1 Kameraların eğim açılarının ve lens aralıklarının belirlenmesi

Önerilen yöntemde kameraların birbirlerine doğru eğimli olmasından kaynaklanan optik eksenlerin eğim açıları, kamera doğrultusunun dışında kalan görüntünün kapladığı alanı etkiler. Bu alan Şekil 3.8’de gösterilmiştir.



Şekil 3.8. Kamera doğrultusunun dışında kalan görüntü alanı

Optik eksenlerin eğim açısı istenilen yol bölgesi alanının kamera görüntülerinde yer almasını sağlayacak şekilde ayarlanmalıdır.

$\beta$ , kameraların optik eksenleri eğim açılarıdır. İki kamera için de bu açı değeri aynıdır.  $\Omega$ , kameraların görüntü alma açılarıdır.  $\theta$  açısı Eşitlik 3.10’da bulunan denklem ile hesaplanır.

$$\theta = \Omega - \beta \quad (3.10)$$

C2V, kameraların önündeki araç plaka bölgesi merkez noktasının bulunduğu yatay doğrultuya olan dik uzaklığıdır. d, C2V doğrultusu ile sol kamera görüntü alanı sol sınır çizgisi arasındaki uzaklıkları ifade eder. Bu uzaklık değeri Eşitlik 3.11’de yer alan denklem ile hesaplanabilir.

$$d = C2V \times \tan \theta \quad (3.11)$$

Eğim açısı ( $\beta$ ) arttıkça  $d$  değerinde azalma meydana gelirken,  $\beta$  değerinin azalması  $d$  değerinin artmasını sağlar. Mesafe tahmininde öndeki aracın sağa veya sola kaymalarında plaka bölgesinin kamera görüntü alanı içerisinde bulunan yol bölgesinde yer alması gereklidir.  $d$  değeri, yol bölgesinin kamera görüntü alanı içerisinde yer alan sınırlarını belirler ve mesafe tahmini bu sınırlar içerisinde yer alan tespit edilmiş plaka bölgeleri üzerinden gerçekleştirilir.  $\beta$  değeri ayarlanarak istenilen  $d$  değeri belirlenebilir.

Önerilen kamera modelinde optik eksen eğim açısının yüksek olması mesafe tahmininde avantaj sağlamaktadır. Aynı zamanda eğim açısının çok artması durumunda kameraların görüntüsüne giremeyen yol bölgesi alanı artar. Hatta açı, görüntü alma açısının yarısı olan 30 derecenin üzerinde olduğunda yol bölgesinin kameralara dik olan doğrultularla sınırları belirlenebilecek alanları kamera görüntülerinin dışına çıkar. Bu sebeple yapılan çalışmada kameraların kritik optik eksen eğim açısı değeri  $20^\circ$  olarak belirlenmiştir.

Yol bölgesinin kamera görüntü alanı içerisinde yer alan sınırlarını belirleyen bir başka faktör kameraların lensleri arasındaki mesafedir. Sağ kameranın lensi ve sol kameranın lensi arasındaki mesafe arttıkça yol bölgesinin kamera görüntü alanı içerisinde yer alan sınırları genişlemiş olur. Kameraların lensleri arası uzaklığın fazla olması aynı zamanda önerilen yöntemde mesafe tahmininde avantaj sağlamaktadır. Bu sebepten ötürü yapılan çalışmada kameralar bir aracın üzerine yerleştirilen tavan barının uçlarına monte edilerek lensleri arasındaki mesafenin mümkün olduğunca artırılması sağlanmıştır. Böylelikle kamera lensleri arasındaki uzaklık değeri 150 cm olarak belirlenmiştir.

### **3.2.2 Materyal**

Çalışmada yatay bir platform üzerine, sabit aralıklı mesafede ve optik eksenleri birbirlerine doğru  $20^\circ$  eğim açısı oluşturacak şekilde konumlandırılan iki kamera kullanılmıştır. Kullanılan kameralar; 1080P full hd (1920x1080) çözünürlükte, A4 Tech marka ve PK-910H model web kameralardır. Kameraların görüntü alma açıları  $60^\circ$ 'dir. Kameraların içerisine yerleştirildiği 3d yazıcı ile polilaktik asit (pla) malzemeden üretilmiş parçalar arabanın üzerine yerleştirilebilen tavan barının uçlarına monte

edilmişlerdir. 3d yazıcı ile üretilen parçalar kameraların optik eksenlerinin birbirlerine doğru yirmişiş derece açı oluşturmasını sağlar niteliktedirler. Web kameraları görüntü alabilmeleri için usb bağlantı kabloları vasıtasıyla bir dizüstü bilgisayara bağlanmıştır. Geliştirilen görüntü alma platformu Şekil 3.9’da görülmektedir.



Şekil 3.9. Görüntü alma platformu

Kameraların optik eksenlerinin yol düzlemiyle paralel doğrultuda olabilmelerini sağlamak için, kameraların araba üzerine monte edilebilen 120 cm uzunluğunda bir tavan barının uçlarına monte edilmesi sağlanmıştır. 3d yazıcı ile üretilen parçalar tavan barının uçlarına monte edildiğinde iki kamera arası lens uzaklığı 150 cm olmaktadır.

Görüntü alma platformunun araç üzerine yerleştirilmiş hali Şekil 3.10’da gösterilmektedir.



Şekil 3.10. Görüntü alma platformunun araç üzerine yerleştirilmiş hali

Çalışmada kullanılan görüntü işleme ve YSA uygulamaları için MATLAB yazılımı R2012b sürümü kullanılmıştır. Kameralardan elde edilen görüntülerin dijital ortama aktarılmasını sağlayan kamera uygulama yazılımı; elde edilen görüntülerin çözünürlüğünü, kameraların çözünürlüğü olan 1920x1080 pikselden 4608x3456 piksele çıkarabilmektedir. Çalışmada 4608x3456 piksel çözünürlüğündeki görüntüler kullanılmıştır.

### **3.3 YSA için Veri Seti Oluşturma**

Önerilen yöntemde öndeki aracın plaka bölgesi merkez noktasının kamera görüntülerindeki koordinat bilgilerine dayalı veriler YSA giriş değerlerini oluşturmaktadır. Geliştirilen YSA modeli öndeki aracın plaka bölgesi merkez noktasının kameraların görüntü koordinatlarındaki farklılıklardan yararlanarak öndeki aracın mesafesine ait bir tahmin sunar.

#### **3.3.1 YSA modeli için aday giriş değişkenlerinin belirlenmesi**

Önerilen kamera modelinde hedef noktanın kameralar içindeki yatay konum değerleri  $\Delta x$  değerini etkiler. Dolayısıyla YSA girdi kümesinde  $\Delta x$  değeri ile birlikte hedef noktanın yatay konum bilgilerini temsil eden değerler bulunmalıdır. Kamera görüntüsünden elde edilen plaka bölgesi merkez noktasının sol ve sağ kenarlardan uzaklığına ait bilgiler öndeki aracın yatay konumu belirler.

Ayrıca iki kameradan elde edilen görüntülerde belirlenen, öndeki aracın plaka bölgesi merkez noktasının koordinat bilgilerinin dikey eksen değerlerine ait farkı ( $\Delta y$ ) ile öndeki aracın plaka bölgesi merkez noktasının dikey koordinatlarına ait bilgiler de  $\Delta x$  değerini etkiler.  $\Delta y$  değeri kameralar yatay olarak aynı hizada yer aldığı anda sıfır değerini alır. Ancak kamera platformunun monte edildiği aracın üzerinde bulunduğu zeminin eğimine bağlı olarak  $\Delta y$  değeri ve öndeki aracın plaka bölgesi merkez noktasının kameraların görüntülerindeki dikey koordinatlarına ait bilgileri değişir. Aracın bulunduğu zeminin eğimi kameralarda dairesel dönme oluşturur. Kameraların

dairesel dönme açlarına bağlı olarak öndeki aracın plaka bölgesi merkez noktasının kamera görüntülerindeki yatay ve dikey koordinat bilgilerinde değişimler meydana gelir. Bu sebeplerden ötürü mesafe tahmini için YSA girdi kümesinde öndeki aracın plaka bölgesinin merkez noktasının yatay koordinatına ait bilgileri ile birlikte dikey koordinat bilgilerinden oluşturulan değerleri de kullanılmıştır.

Mesafe tahmini için oluşturulan YSA modelinde kullanılacak girdi verilerini belirleyen, sağ ve sol kameralardan elde edilen görüntülerden belirlenen öndeki araç plaka bölgesi merkez noktası yatay ve dikey koordinat bilgileri kullanılarak oluşturulan on adet aday giriş değişkeni belirlenmiştir.

Belirlenen aday giriş değişkenleri aşağıdaki gibidir:

1. A kamera görüntüsünden elde edilenler
  - a. Plaka bölgesi merkez noktasının çerçeve sol kenarından uzaklığı ( $AX_1$ )
  - b. Plaka bölgesi merkez noktasının çerçeve sağ kenarından uzaklığı ( $AX_2$ )
  - c. Plaka bölgesi merkez noktasının çerçeve üst kenarından uzaklığı ( $AY_1$ )
  - d. Plaka bölgesi merkez noktasının çerçeve alt kenarından uzaklığı ( $AY_2$ )
2. B kamera görüntüsünden elde edilenler
  - a. Plaka bölgesi merkez noktasının çerçeve sol kenarından uzaklığı ( $BX_1$ )
  - b. Plaka bölgesi merkez noktasının çerçeve sağ kenarından uzaklığı ( $BX_2$ )
  - c. Plaka bölgesi merkez noktasının çerçeve üst kenarından uzaklığı ( $BY_1$ )
  - d. Plaka bölgesi merkez noktasının çerçeve alt kenarından uzaklığı ( $BY_2$ )
3. A ve B kamera görüntülerinin eşleştirilmesi ile elde edilenler
  - a.  $\Delta x$
  - b.  $\Delta y$


### 3.3.2 Görüntü örneklerinin toplanması

Belirlenen aday giriş değişkenlerine bağlı olarak YSA girdi değerleri oluşturulurken ön aracın sağ ve sol kameralardan elde edilen görüntü örneği çiftleri kullanılmıştır. Önerilen yöntemde hedef noktanın kamera görüntülerindeki yatay konum değerleri,  $\Delta x$  değerlerini etkilediğinden mesafe tahmininde önemlidir. Bu yüzden görüntü örneği

çiftleri toplanırken ön aracın farklı uzaklıklardaki görüntülerinin yanında farklı yatay konumdaki görüntülerinden yararlanılmıştır. Bu şekilde geliştirilen YSA modeli ön aracın farklı uzaklıkları ile birlikte farklı yatay konumları için eğitilmiştir.

YSA veri setini oluşturmak için üzerinde kamera platformu bulunan araçtan ön aracın 1-60 m'lik toplam mesafesi boyunca 1 m aralıklarla alınan görüntüler kullanılmıştır. Her uzaklık değeri için 50 cm aralıklarla sağdan ve soldan ön aracın üçer görüntü örneği çifti daha alınmıştır. Elde edilen 414 görüntü örneği çifti aday giriş değişkenlerine ait veri setinin oluşturulması için kullanılmıştır. Ön aracın 3 m'ye kadar olan görüntülerinden 150 cm sağda ve 150 cm solda olanlarında plaka bölgeleri görüntü alanları dışına taştığı için bu görüntüler kullanılmamıştır.

Şekil 3.11'de, görüntü örnekleri alınırken ön aracın uzaklıklarını ve pozisyonlarını gösteren bir şema yer almaktadır.



Şekil 3.11. Veri seti için örnekler alma

Görüntü alınan araçta, kamera platformu orta noktası ile aracın ön uç noktası arasında 2.2 m mesafe bulunmaktadır. Kamera platformu ile ön araç arasındaki mesafe bu değerle görüntü alınan araç ile ön araç arasındaki uzaklığa eklenmesi ile elde edilir. Önerilen yöntemle elde edilen sonuçlar kamera platformunun ön araca olan uzaklığına aittir. İki araç arası mesafe elde edilen sonuçlardan 2.2 m çıkarılması ile bulunabilir. Veri seti oluşturulurken kamera platformuyla ön araç arasındaki mesafe dikkate alınmış olup ölçülen uzaklıklara 2.2 m değeri eklenmiştir.

### **3.3.3 Görüntü örneklerinden plaka merkez noktasının belirlenmesi**

Ön aracın belirlenen konumlarından alınan görüntü örneği çiftlerinden, belirlenen aday giriş değişkenleri parametrelerine ait bilgiler elde edilerek veri setine dâhil edilmektedir. Aday giriş değişkenleri parametrelerine ait bilgilerin elde edilmesi için görüntülerdeki ön aracın plaka bölgesi merkez noktasının görüntü koordinatları belirlenmektedir. Bunun için ilk olarak görüntülerdeki ön aracın plaka bölgesinin tespiti gerçekleştirilmektedir. Daha sonra tespit edilen plaka bölgelerinin, merkez noktalarına ait görüntü koordinatları bulunarak aday giriş değişkenlerine ait bilgiler hesaplanmaktadır.

Plaka bölgesinin tespit edilmesinde bazı sınırlamalar bulunmaktadır. Bu çalışmada plaka tespiti için ön aracın kameralardan 62.2 m uzaklığa kadar olan görüntüleri kullanılmaktadır. Bir görüntüdeki araç plaka bölgesini tespit etmeye yönelik bazı çalışmalar mevcuttur (Safaei ve ark., 2016; Rafique ve ark., 2017; Asif ve ark., 2019). Ancak bu çalışmalar yakın mesafeler içindir ve mesafe bilgisi verilmemiştir. Lalimi ve ark. (2013); önermiş oldukları yöntemle plaka bölgesinin ön aracın 12 m'ye kadar olan uzaklıkları için belirlenebildiğini belirtmektedir. Yuan ve ark., (2017) tarafından önerilen plaka bölgesi tespit yöntemi, ön aracın 5m ve 15m arasındaki uzaklıklarından alınan görüntüleri için uygulanmaktadır. Uzak mesafelerde bulunan plaka bölgelerinin kamera görüntüleri üzerinde kapladığı alanlar küçüleceğinden tespit edilmeleri yakın mesafelere kıyasla daha zor olmaktadır. Kullanılan kameraların donanımsal özellikleri ve ortam aydınlatmasının çok fazla veya çok düşük olması gibi faktörler görüntüler üzerindeki plaka bölgesinin tam olarak tespit edilememesine yol açabilmektedir.

Önerilen yöntemde uygulanan metodolojinin test edilmesi için geniş ölçekli bir veri setine ihtiyaç vardır. Yakın mesafelerden alınan görüntü örneklerine dayalı bir uygulamada veri seti son derece sınırlı sayıda bilgilerden oluşmaktadır ve metodolojinin uygulanabilirliği yeterince test edilememektedir. Bu yüzden bu çalışmada görüntülerde yer alan plaka bölgelerinin tespiti manuel olarak yapılmıştır.

Şekil 3.12’de kamera platformundan 8.2 m uzaklıkta ve plaka bölgesi merkez noktası kamera platformu orta noktasına göre 0.5 m sağa sapma pozisyonunda bulunan bir araca ait sol ve sağ kameralardan elde edilen görüntüler bulunmaktadır.



Şekil 3.12. Stereo kamera görüntüleri (a: Sol kameradan elde edilen görüntü ve b: Sağ kameradan elde edilen görüntü)

Sol ve sağ kameralardan elde edilen görüntüler ilk aşamada üzerinde kolay işlem yapılabilmesi için gri seviyeli görüntülere dönüştürülmüştür. Daha sonra iki boyutlu görüntülere 3x3 boyutunda medyan filtre uygulanarak görüntülerdeki gürültü kaldırılmıştır. Gri seviyeli görüntülerden plaka bölgesine ait bölgenin başlangıç ve bitiş koordinatları manuel olarak belirlenmiştir.

Şekil 3.13’de, plaka bölgelerinin belirlenen başlangıç ve bitiş noktalarına ait koordinatları görülmektedir.



Şekil 3.13. Plaka bölgeleri belirlenmiş stereo kamera görüntüleri (a: Sol kamera görüntüsü ve b: Sağ kamera görüntüsü)

Sol ve sağ kamera görüntülerinde yer alan plaka bölgeleri merkez noktalarının görüntü koordinatlarındaki x eksenlerine ait değerleri, başlangıç noktalarının x eksenine ait değerleri ve bitiş noktalarının x eksenine ait değerlerinin ortalamasıdır. Bu değerler şu şekilde bulunur:

$$CPA_x = \frac{(SPA_x + FPA_x)}{2} \quad (3.12)$$

$$CPB_x = \frac{(SPB_x + FPB_x)}{2} \quad (3.13)$$

$CPA_x$  ve  $CPB_x$ ; sırasıyla sol ve sağ kamera görüntülerinde yer alan plaka bölgeleri merkez noktalarının görüntü koordinatlarındaki x eksenlerine ait değerleridir.  $SPA_x$  ve  $SPB_x$ ; sırasıyla sol ve sağ kamera görüntülerinde yer alan plaka bölgelerinin başlangıç noktalarına ait görüntü koordinatlarının x eksen değeri değerleridir.  $FPA_x$  ve  $FPB_x$ ; sırasıyla sol ve sağ kamera görüntülerinde yer alan plaka bölgelerinin bitiş noktalarına ait görüntü koordinatlarının x eksen değeri değerleridir.

Sol ve sağ kamera görüntülerinde yer alan plaka bölgeleri merkez noktalarının görüntü koordinatlarındaki y eksenlerine ait değerleri, plaka bölgeleri başlangıç noktalarının y eksenine ait değerleri ve plaka bölgeleri bitiş noktalarının y eksenine ait değerlerinin ortalamasıdır. Bu değerler şu şekilde bulunur:

$$CPA_y = \frac{(SPA_y + FPA_y)}{2} \quad (3.14)$$

$$CPB_y = \frac{(SPB_y + FPB_y)}{2} \quad (3.15)$$

$CPA_y$  ve  $CPB_y$ ; sırasıyla sol ve sağ kamera görüntülerinde yer alan plaka bölgeleri merkez noktalarının görüntü koordinatlarındaki y eksenlerine ait değerleridir.  $SPA_y$  ve  $SPB_y$ ; sırasıyla sol ve sağ kamera görüntülerinde yer alan plaka bölgelerinin başlangıç noktalarına ait görüntü koordinatlarının y eksenleri değerleridir.  $FPA_y$  ve  $FPB_y$ ; sırasıyla sol ve sağ kamera görüntülerinde yer alan plaka bölgelerinin bitiş noktalarına ait görüntü koordinatlarının y eksenleri değerleridir.

### 3.3.4 Aday giriş değişkenlerine ait veri seti değerlerinin belirlenmesi

Kamera görüntülerinde yer alan plaka bölgesi merkez noktalarının koordinat bilgilerinden yararlanılarak aday giriş değişkenlerine ait veri seti değerleri hesaplanmaktadır. Bu değerler verilen şu denklemler ile hesaplanabilir:

$$AX1 = CPA_x \quad (3.16)$$

$$AX2 = HFOV_{px} - CPA_x \quad (3.17)$$

$$AY1 = CPA_y \quad (3.18)$$

$$AY2 = VFOV_{py} - CPA_y \quad (3.19)$$

$$BX1 = CPB_x \quad (3.20)$$

$$BX2 = HFOV_{px} - CPB_x \quad (3.21)$$

$$BY1 = CPB_y \quad (3.22)$$

$$BY2 = VFOV_{py} - CPB_y \quad (3.23)$$


$$\Delta X = HFOV_{px} - AX1 - BX2 \quad (3.24)$$

$$\Delta Y = VFOV_{px} - AY1 - BY2 \quad (3.25)$$

Denklemlerde yer alan  $VFOV_{px}$ , kamera görüntüsündeki dikey eksende bulunan piksel sayısını ifade eder.

Belirlenen plaka bölgelerinin kenar çizgilerini aynı görüntü üzerinde bir araya getirmek için daha önce oluşturulan iki sıfır matrisi dışında üçüncü bir sıfır matrisi oluşturulur. Bu sıfır matrisinin boyutları da stereo görüntülerin boyutlarıyla aynıdır. Daha önce tanımlanmış olan plaka bölgelerine ait koordinat bilgilerini içeren matrisler bu defa plaka bölgelerinin kenarlarını, oluşturulan üçüncü sıfır matrisi üzerine çizmek için kullanılır. Daha önce oluşturulan sıfır matrisleri üzerinde belirlenen plaka bölgelerinin merkez noktalarına ait koordinat bilgileri çıkarılır. Bu koordinat bilgilerinden yararlanılarak aday değişkenlere ait değerler hesaplanmıştır.

Şekil 3.14'te, kamera platformu orta noktasına göre 8.2 m uzaklıkta ve 0.5 m yatay sapma pozisyonunda bulunan öndeki araç plaka bölgesi merkez noktası için aday giriş değişkenleri veri seti değerleri ve kamera görüntülerinde yer alan plaka bölgelerinin bir görüntüde gösterimi yer almaktadır.

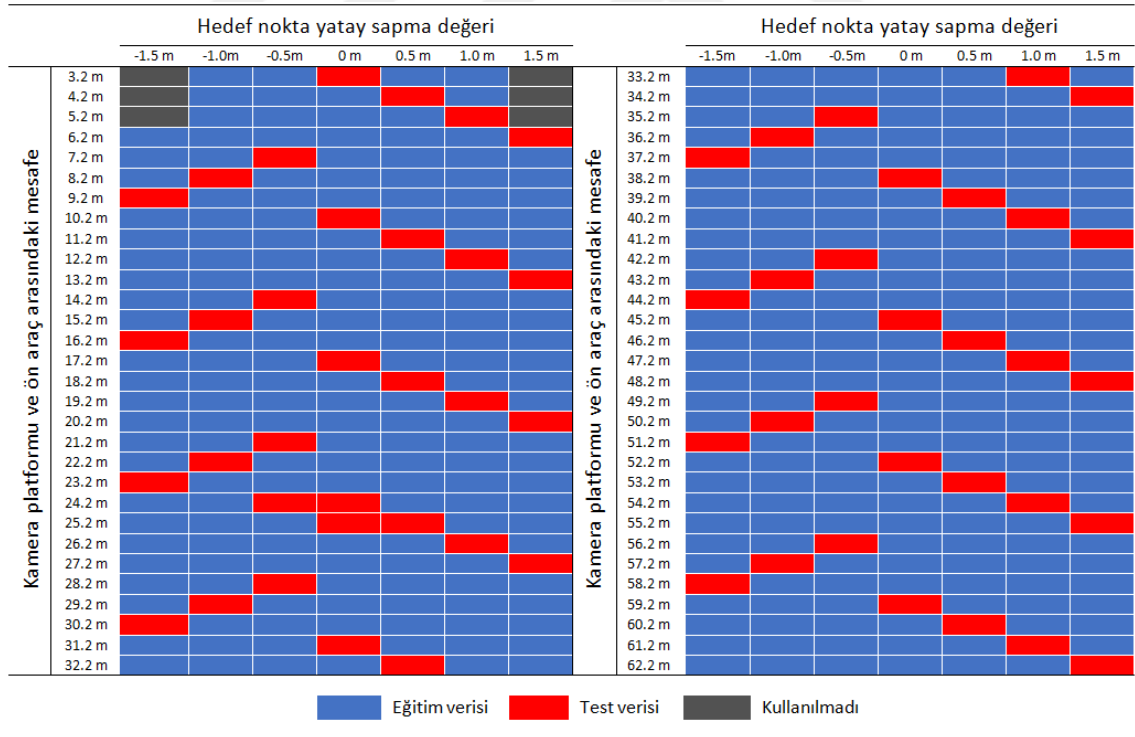


Şekil 3.14. Aday giriş değişkenleri veri seti değerleri ve plaka bölgeleri (bir görüntü içerisinde)

### 3.4 Yapay Sinir Ağının Modellenmesi

YSA modellemesi yapılırken verilerin ağa sunulmadan önce bölümlenmesi gerekmektedir. Veriler; eğitim, doğrulama ve test olmak üzere üçe veya eğitim ve test olmak üzere ikiye bölünebilmektedir. Zhang ve ark. (1998)'a göre ikiye bölünen veriler için %90 eğitim ve %10 test ile %70 eğitim ve %30 test değerleri arasında bölümlenmeler yapılabilir. YSA modellemesi, verilerin %85'inin eğitim verisi ve %15'inin test verisi olduğunu belirlemiştir. Böylece toplam 414 görüntü örneği çiftinin; 352'si eğitim verilerinin bir parçası olarak, 62'si test verilerinin parçası olarak sınıflandırılmıştır.

Şekil 3.15'te, öndeki aracın elde edilen görüntü örneği çiftlerinin eğitim verilerinin bir parçası veya test verilerinin bir parçası olarak sınıflandırılmasına ait gösterim bulunmaktadır.



Şekil 3.15. Görüntü örneklerinin eğitim ve test verilerinin parçası olarak sınıflandırılması

İlk olarak, ön aracın kamera platformu için 3.2-62.2 m genel mesafesi arasındaki her 1 m mesafesinde bulunan farklı yatay sapma pozisyonlarındaki görüntü örneği çiftlerinden yalnızca 1 tanesi test verilerinin bir parçası olarak sınıflandırılmıştır. Daha sonra bu seçime dâhil edilmemiş tüm görüntü örneği çiftleri arasından rastgele seçilen iki görüntü örneği çifti daha seçime eklenerek test verilerine ait sınıflandırma tamamlanmıştır. Yapılan sınıflandırmada her uzaklık değeri için ve her yatay sapma pozisyonu değeri için oluşturulan görüntü örneklerinden mümkün olduğunca eşit oranda seçilerek, bu seçimlerin test verilerinin bir parçası olarak belirlenmesi sağlanmıştır. Aynı zamanda; YSA eğitimi için kullanılan girdi kümelerinde, öndeki aracın her uzaklık değeri için ve her yatay sapma pozisyonu değeri için oluşturulan görüntü örneklerinden eşit oranda yararlanılması sağlanmıştır. Böylece YSA eğitiminde öndeki aracın herhangi bir uzaklığı veya herhangi bir yatay sapma pozisyonu için yetersiz örnek kullanılmasının önüne geçilmiştir. Bu durum, öndeki aracın herhangi bir uzaklığı veya herhangi bir yatay sapma pozisyonunu için elde edilen mesafe tahmin sonuçlarında yüksek hata oranı oluşmamasını sağlamaktadır.

Görüntü örneği çiftlerinden elde edilerek veri setine dâhil edilen veriler 0 ile 1 arasında normalize edilerek ağa sunulmuştur. Geri yayımlı öğrenme YSA modelinde verilerin normalleştirilmesi şart değildir. Ancak verilerin normalleştirilmesi ağ performansını artırır (Buckland ve Collins, 2002).

Tahmin için modellenmesi yapılan sinir ağlarında, literatürde yapılan birçok çalışmada gizli katman sayısı bir olan ve çıktı katmanında bir tane nörona sahip olan ağların etkin sonuçlar vermede başarılı oldukları görülmüştür (Cybenko, 1989). Yapılan YSA modellenmesinde, gizli katman sayısı 1 ve çıkış katmanında bulunan nöron sayısı 1 olarak belirlenmiştir.

YSA'da en çok tercih edilen transfer fonksiyonlarından biri Hiperbolik Tanjant fonksiyonudur (Demuth ve Beale, 2004). Bir diğer en çok tercih edilen aktivasyon fonksiyonu ise Sigmoid fonksiyonudur (Demuth ve Beale, 2004; Irmakçı, 2008). YSA modelinin gizli katmanı için "Hiperbolik Tanjant Fonksiyonu"; çıkış katmanı için "Sigmoid Fonksiyonu" tercih edilmiştir.

Denenen YSA modellerinde “Scaled Conjugate Gradient Backpropagation” öğrenme algoritması tercih edilmiştir. Deneme yanılma yoluyla yapılan değerlendirmeler ile bu algoritmanın iyi sonuçlar verdiği sonucuna ulaşılmıştır.

Deneme yanılma yöntemiyle belirlenen değerlere göre denenen YSA modellerinde uygulanan öğrenme oranı 0.8, momentum katsayısı ise 0.6 olarak belirlenmiştir. Performans ölçütü olarak MSE değeri; performans hedefi ise  $10^{-8}$  olarak belirlenmiştir.

### *Giriş değişkenlerini belirleme yöntemi*

Aday giriş değişkenlerinden hangilerinin oluşturulacak YSA modelinde giriş değişkenleri olarak kullanılacağını belirlemek üzere öncelikle aday giriş değişkenleri iki gruba ayrılmıştır. Birinci grupta yatay eksen konum bilgilerine bağlı değişkenlerin bulunduğu kümeler, ikinci grupta ise dikey eksen konum bilgilerine bağlı değişkenlerin bulunduğu kümeler yer almaktadır. Çizelge 3.2’de belirlenen aday giriş değişkenleri kümelerine ait gruplar bulunmaktadır.

Çizelge 3.2. Belirlenen değişken kümesi grupları

A. Yatay Eksen Konum Bilgilerine Bağlı Değişken Kümeleri	1. $AX_1 - BX_1 - \Delta x$
	2. $AX_1 - AX_2 - BX_1 - BX_2 - \Delta x$
B. Dikey Eksen Konum Bilgilerine Bağlı Değişken Kümeleri	1. $\Delta y$
	2. $AY_1 - BY_1 - \Delta y$
	3. $AY_1 - AY_2 - BY_1 - BY_2 - \Delta y$

Birinci grupta yer alan kümeler temel alınmak üzere; bu gruptaki kümeler ve bu gruptaki kümelerin ikinci grupta olan kombinasyonlarıyla elde edilen 8 adet aday giriş değişkeni kümesi belirlenmiştir. Elde edilen aday giriş değişkeni kümeleri şu şekildedir:

1.  $AX_1 - BX_1 - \Delta x$
2.  $AX_1 - AX_2 - BX_1 - BX_2 - \Delta x$
3.  $AX_1 - BX_1 - \Delta x - \Delta y$
4.  $AX_1 - AY_1 - BX_1 - BY_1 - \Delta x - \Delta y$

5.  $AX_1 - AY_1 - AY_2 - BX_1 - BY_1 - BY_2 - \Delta x - \Delta y$
6.  $AX_1 - AX_2 - BX_1 - BX_2 - \Delta x - \Delta y$
7.  $AX_1 - AX_2 - AY_1 - BX_1 - BX_2 - BY_1 - \Delta x - \Delta y$
8.  $AX_1 - AX_2 - AY_1 - AY_2 - BX_1 - BX_2 - BY_1 - BY_2 - \Delta x - \Delta y$

Elde edilen bu 8 aday giriş değişkeni kümesinden hangisinin kullanılacağı bu giriş değişkenleriyle birlikte farklı nöron sayıları ve farklı iterasyon sayılarıyla yapılan denemeler sonucunda belirlenmiştir. Yapılan denemeler ile en iyi hata değerine sahip YSA modeli belirlenmektedir. Böylelikle bu modele hangi giriş değişkenleri, nöron sayısı ve iterasyon sayısı ile ulaşıldığı belirlenmektedir.

Yıldız (2016) ve Sönmez Çakır (2019)'a göre literatürde yer alan bazı çalışmalarda YSA gizli katman nöron sayısının belirlenmesi ile ilgili hesaplamalar bulunmaktadır. Çizelge 3.3'te bu hesaplamalara ait denklemler verilmiştir. Denklemlerde belirtilen  $n$ , nöron sayısını;  $n_i$ , giriş değişkeni sayısını;  $n_o$ , çıkış değişkeni sayısını ve  $n_t$ , giriş ve çıkış değişkenlerinin toplam sayısını ifade etmektedir.

Çizelge 3.3. Gizli katman nöron sayısı belirleme denklemleri

Çalışma	Önerilen hesaplama denklemi
(Wong, 1991)	$n = 2n_i$
(Tang ve Fishwick, 1993)	$n = n_i$
(Masters, 1993; Shibata ve Ikeda, 2009)	$n = \sqrt{n_i n_o}$
(Li ve ark., 1995)	$n = (\sqrt{1 + 8n_i} - 1)/2$
(Tamura ve Tateishi, 1997)	$n = n_t - 1$
(Zang ve ark., 2003)	$n = 2^{n_i}/(n_i + 1)$
(Hunter ve ark., 2012)	$n = 2^{n_i} - 1$
(Sheela ve Deepa, 2013)	$n = (4n_i^2 + 3)/(n_i^2 - 8)$

Elde edilen 8 aday giriş değişkeni kümesinin her biri için bu hesaplamalar kullanılarak hangi nöron sayılarıyla denemeler yapılacağı belirlenmiştir. Ayrıca deneme yanılma yoluyla elde edilen sonuçlarda gizli katmanında 15 nöron bulunan YSA modelinin bütün aday değişken kümeleri için iyi sonuçlar verdiği gözlemlenmiştir. Bu sebeple

aday giriş değişken kümeleri için hesaplama denklemleriyle belirlenmiş olan nöron sayılarının yanında sabit 15 nöron sayısı da kullanılmıştır. Belirlenen bu nöron sayılarının her biri için 10 000 iterasyondan 100 000 iterasyona kadar 10 000'er artış ile sırasıyla 10 000, 20 000, 30 000, 40 000, 50 000, 60 000, 70 000, 80 000, 90 000 ve 100 000 iterasyon için denemeler yapılmıştır. Çizelge 3.4'te her bir aday giriş değişken kümesi için hangi nöron sayıları ve hangi iterasyon sayılarıyla denemeler yapıldığı belirtilmiştir.

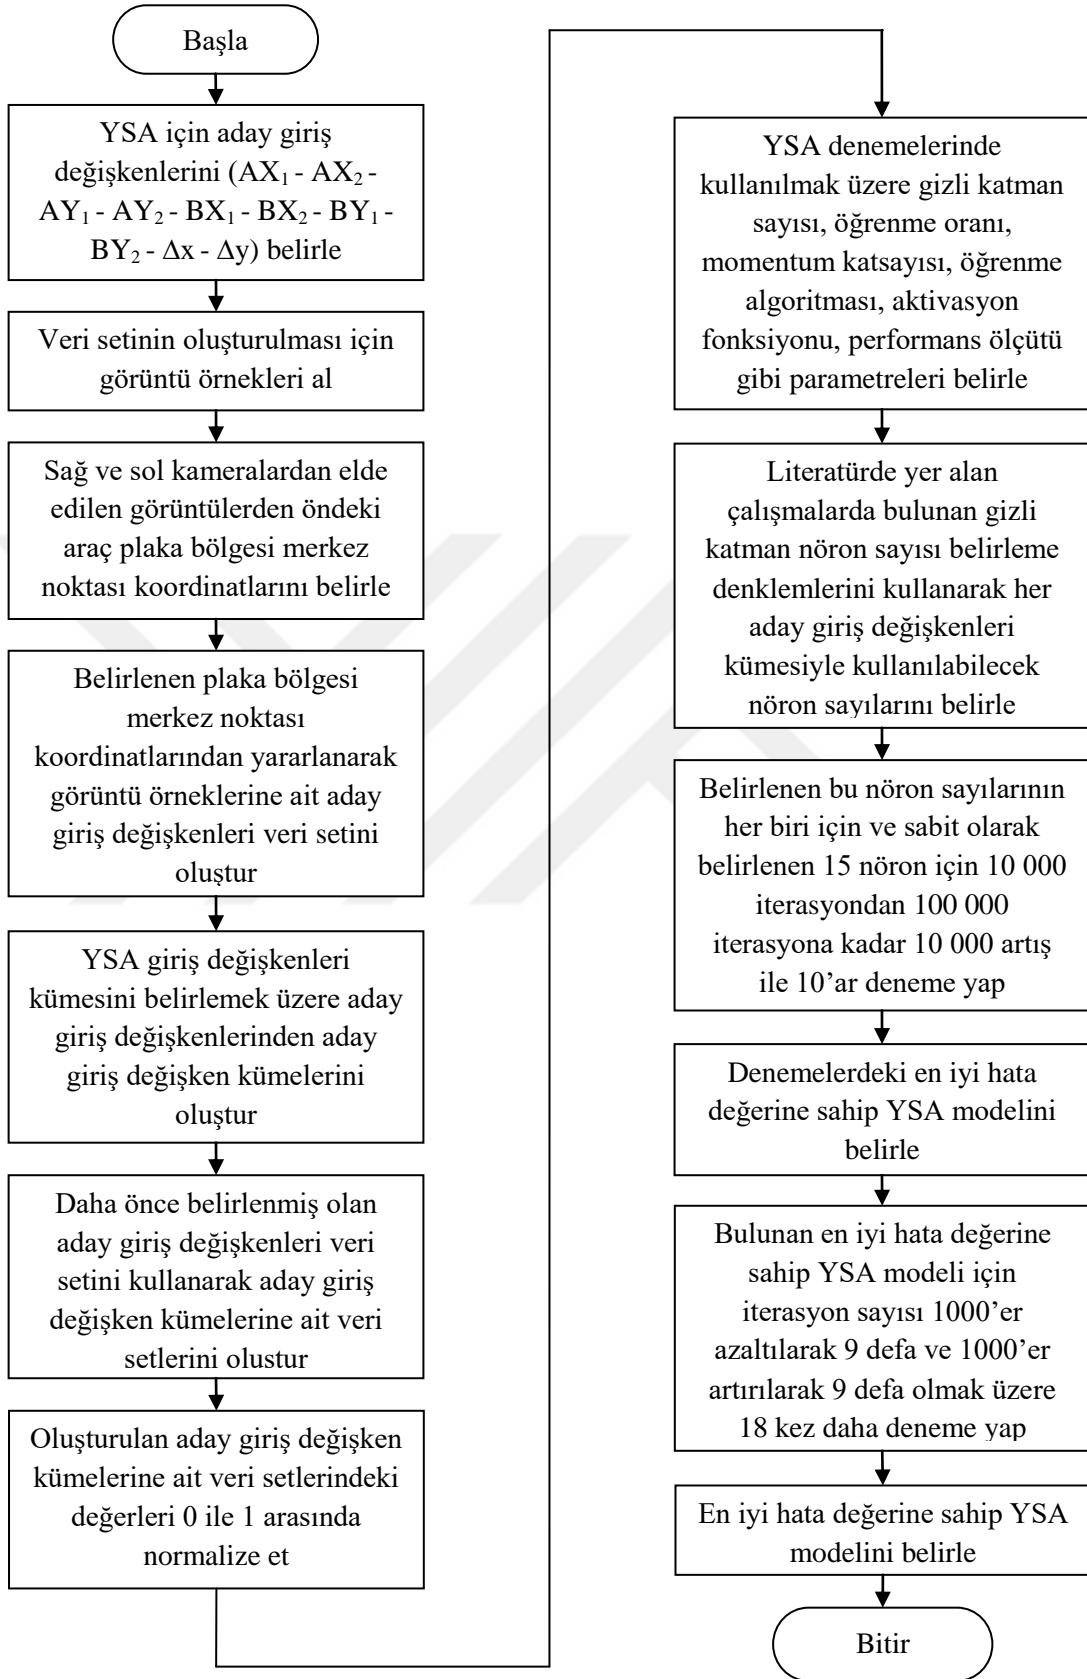
Çizelge 3.4. Aday giriş değişken kümeleri için belirlenen nöron sayıları

Aday giriş değişken kümeleri	Denemesi yapılan nöron sayıları	Denemesi planlanan iterasyon sayıları
$AX_1 - BX_1 - \Delta x$	2 - 3 - 6 - 7 - 15 - 39	Her aday giriş değişken kümesine ait bütün nöron sayısı denemeleri için 10 000 ile 100 000 iterasyon arasında 10 000 artışla 10 deneme (10 000 - 20 000 - 30 000 - 40 000 - 50 000 - 60 000 - 70 000 - 80 000 - 90 000 - 100 000 ).
$AX_1 - AX_2 - BX_1 - BX_2 - \Delta x$	2 - 3 - 5 - 6 - 10 - 15 - 31	
$AX_1 - BX_1 - \Delta x - \Delta y$	2 - 3 - 4 - 8 - 15	
$AX_1 - AY_1 - BX_1 - BY_1 - \Delta x - \Delta y$	2 - 3 - 4 - 6 - 9 - 12 - 15 - 63	
$AX_1 - AY_1 - AY_2 - BX_1 - BY_1 - BY_2 - \Delta x - \Delta y$	3 - 4 - 5 - 8 - 15 - 16 - 28 - 255	
$AX_1 - AX_2 - BX_1 - BX_2 - \Delta x - \Delta y$	2 - 3 - 4 - 6 - 9 - 12 - 15 - 63	
$AX_1 - AX_2 - AY_1 - BX_1 - BX_2 - BY_1 - \Delta x - \Delta y$	3 - 4 - 5 - 8 - 15 - 16 - 28 - 255	
$AX_1 - AX_2 - AY_1 - AY_2 - BX_1 - BX_2 - BY_1 - BY_2 - \Delta x - \Delta y$	3 - 4 - 10 - 15 - 20 - 93 - 1023	

Denemeler sonucunda bulunan en iyi hata değerine sahip YSA modeli, iterasyon sayısı 1000'er azaltılarak 9 defa ve 1000'er artırılarak 9 defa olmak üzere 18 kez daha denenmiştir. Bu yöntemle; yapılan denemeler içinde en iyi sonucu veren YSA modeli tespit edilerek, bu modele ait giriş değişkeni kümesi, gizli katmanda kullanılacak nöron sayısı ve iterasyon sayısı belirlenmiştir.

Denemeler sonucunda bulunan en iyi değerlendirme sonucu, çıkış değerleri ve gerçek değerlerin karşılaştırılmasıyla elde edilen MAPE, MSE ve RMSE hata değerleri ile korelasyon katsayılarının değerlendirilmeleri yapılarak belirlenmiştir.

YSA modellemesine ait işlem adımlarını gösteren akış şeması Şekil 3.16'da verilmiştir.



Şekil 3.16. Önerilen yöntemle ait YSA tasarımı akış diyagramı

## 4. BULGULAR

Bu bölümde ilk olarak sırasıyla bütün aday giriş değişken kümeleri için literatürde yer alan çalışmalardaki gizli katman nöron sayısı hesaplama denklemleri ile hesaplanan nöron sayılarıyla ve deneme yanılma yoluyla belirlenen sabit 15 nöron sayısıyla yapılan deneme sonuçlarına ait bazı bulgulara yer verilmiştir. Deneme sonuçlarına ait bulgular; YSA çıktı değerleri ile gerçek değerler arasındaki MAPE, MSE, RMSE ve R performans değerlendirme ölçütlerine ait değerleri içerir. Her giriş değişkenleri kümesi için, belirlenen nöron sayılarıyla farklı iterasyonlarda gerçekleştirilen denemelerden MAPE değerleri temel alınarak en iyi hata oranına sahip modeller birbirleriyle karşılaştırılmaktadır.

Son olarak aday giriş değişken kümeleriyle yapılan denemelerde en iyi performans değerlerine ulaşılan modeller karşılaştırılarak en iyi performansa sahip YSA modeli belirlenmiştir. Böylece yapılan denemelerde bulunan en iyi performansa sahip YSA modelinin giriş değişkenleri, gizli katmanındaki nöron sayısı ve iterasyon sayısı tespit edilmiştir.

Yapılan denemelerde daha önce belirtildiği üzere gizli katman sayısı 1, öğrenme algoritması “Scaled Conjugate Gradient Backpropagation”, gizli katman aktivasyon fonksiyonu olarak “Hiperbolik Tanjant Fonksiyonu”, çıkış katmanı aktivasyon fonksiyonu olarak “Sigmoid Fonksiyonu”, öğrenme oranı 0.8 ve momentum katsayısı 0.6 seçilmiştir.

### 4.1 Birinci Aday Giriş Değişkenleri Kümesine Ait Bulgular

Çizelge 4.1’de önerilen yöntem kullanılarak birinci kümede yer alan aday giriş değişkenleri ile yapılan denemelerde en iyi performans değerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelge 4.1. Birinci değişken kümesine ait performans değerleri

Giriş değişkenleri	Nöron sayısının hangi çalışma ile belirlendiği	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
AX <sub>1</sub> - BX <sub>1</sub> - Δx	(Li ve ark., 1995; Zhang ve ark., 2003; Shibata ve Ikeda, 2009)	2	2714	4.4551	2.6784	1.6366	0.99801
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997)	3	3183	4.3624	2.6893	1.6399	0.998
	(Wong, 1991)	6	3664	2.9393	2.6163	1.6175	0.99805
	(Hunter ve ark., 2012)	7	8721	2.9165	2.6199	1.6186	0.99805
	(Sheela ve Deepa, 2013)	39	90000	5.6663	2.2243	1.4914	0.99835
	-	<b>15</b>	<b>60000</b>	<b>2.816</b>	<b>1.8687</b>	<b>1.367</b>	<b>0.99861</b>

Çizelgede belirtilen denemelerden gizli katmanında 2, 3, 6 ve 7 nöron bulunan modellere ait denemelerde öğrenme algoritmasında kullanılan gradyan iniş değeri hedef değere ulaştığı için iterasyonlar belirlenen tekrardan daha önce tamamlanmıştır. Diğer nöron sayılarıyla; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılan denemelerden sadece en iyi performans değerlerine sahip iterasyon ile yapılan denemeye ait bilgiler çizelgede yer almaktadır.

Bütün performans ölçütlerine ait değerler incelendiğinde; 15 nöron ve 60000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir.

## 4.2 İkinci Aday Giriş Değişkenleri Kümesine Ait Bulgular

Çizelge 4.2’de önerilen yöntem kullanılarak ikinci kümede yer alan aday giriş değişkenleri ile yapılan denemelerde en iyi performans değerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelgede belirtilen denemelerden gizli katmanında 2, 3, 5, 6 ve 10 nöron bulunan modellere ait denemelerde öğrenme algoritmasında kullanılan gradyan iniş değeri hedef değere ulaştığı için iterasyonlar belirlenen tekrardan daha önce tamamlanmıştır. Diğer nöron sayılarıyla; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılan denemelerden sadece en iyi performans değerlerine sahip iterasyon ile yapılan denemeye ait bilgiler çizelgede yer almaktadır.

Çizelge 4.2. İkinci değişken kümesine ait performans değerleri

Giriş değişkenleri	Nöron sayısının hangi çalışma ile belirlendiği	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
AX <sub>1</sub> - AX <sub>2</sub> - BX <sub>1</sub> - BX <sub>2</sub> - Δx	(Shibata ve Ikeda, 2009)	2	2683	4.4872	2.6816	1.6376	0.99801
	(Li ve ark., 1995)	3	3096	4.4463	2.6896	1.64	0.998
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997; Zhang ve ark., 2003)	5	7320	3.0105	2.6188	1.6183	0.99805
	(Sheela ve Deepa, 2013)	6	9166	2.9791	2.6139	1.6168	0.99806
	(Wong, 1991)	10	9250	3.275	2.4429	1.563	0.99818
	(Hunter ve ark., 2012)	31	70000	3.2459	<b>1.777</b>	<b>1.3331</b>	<b>0.99868</b>
-	-	15	20000	<b>2.7238</b>	2.3572	1.5353	0.99825

MAPE değerleri dikkate alındığında; 15 nöron ve 20000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir. MSE, RMSE ve R değerlerine göre gizli katmanında 31 nöron bulunduran model ile 70000 iterasyonda yapılan deneme en iyi performansa sahiptir.

### 4.3 Üçüncü Aday Giriş Değişkenleri Kümesine Ait Bulgular

Çizelge 4.3'te önerilen yöntem kullanılarak üçüncü kümede yer alan aday giriş değişkenleri ile yapılan denemelerde en iyi performans değerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelge 4.3. Üçüncü değişken kümesine ait performans değerleri

Giriş değişkenleri	Nöron sayısının hangi çalışma ile belirlendiği	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
AX <sub>1</sub> - BX <sub>1</sub> - Δx - Δy	(Li ve ark., 1995; Shibata ve Ikeda, 2009)	2	5167	4.2742	2.1354	1.4613	0.99841
	(Zhang ve ark., 2003)	3	8654	4.1557	1.8287	1.3523	0.99864
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997)	4	9809	4.1634	2.1891	1.4796	0.99837
	(Wong, 1991; Sheela ve Deepa, 2013)	8	15433	3.4463	<b>1.5605</b>	<b>1.2492</b>	<b>0.99884</b>
	(Hunter ve ark., 2012)	15	90000	<b>3.1983</b>	1.6701	1.2923	0.99876

Çizelgede belirtilen denemelerden gizli katmanında 2, 3, 4 ve 8 nöron bulunan modellere ait denemelerde öğrenme algoritmasında kullanılan gradyan iniş değeri hedef değere ulaştığı için iterasyonlar belirlenen tekrardan daha önce tamamlanmıştır. Gizli katmanında 15 nöron bulunduran model ile; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılan denemelerden sadece en iyi performans değerlerine sahip iterasyona ait değerler çizelgeye yansıtılmıştır.

MAPE değerleri dikkate alındığında; 15 nöron ve 90000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir. MSE, RMSE ve R değerlerine göre gizli katmanında 8 nöron bulunduran model ile 15433 iterasyonda yapılan deneme en iyi performansa sahiptir.

#### **4.4 Dördüncü Aday Giriş Değişkenleri Kümesine Ait Bulgular**

Çizelge 4.4'te önerilen yöntem kullanılarak dördüncü kümede yer alan aday giriş değişkenleri ile yapılan denemelerde en iyi performans değerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelgede belirtilen denemelerden gizli katmanında 2, 3, 4 ve 6 nöron bulunan modellere ait denemelerde öğrenme algoritmasında kullanılan gradyan iniş değeri hedef değere ulaştığı için iterasyonlar belirlenen tekrardan daha önce tamamlanmıştır. Diğer nöron sayılarıyla; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılabilen denemelerden sadece en iyi performans değerlerine sahip iterasyona ait değerler çizelgeye yansıtılmıştır.

MAPE değerleri dikkate alındığında; 15 nöron ve 60000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir. MSE, RMSE ve R değerlerine göre gizli katmanında 12 nöron bulunduran model ile 70000 iterasyonda yapılan deneme en iyi performansa sahiptir.

Çizelge 4.4. Dördüncü değişken kümesine ait performans değerleri

Giriş değişkenleri	Nöron sayısının hangi çalışma ile belirlendiği	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
AX <sub>1</sub> - AY <sub>1</sub> - BX <sub>1</sub> - BY <sub>1</sub> - Δx - Δy	(Shibata ve Ikeda, 2009)	2	3732	4.1747	1.7122	1.3085	0.99873
	(Li ve ark., 1995)	3	7281	4.4677	1.6552	1.2866	0.99877
	(Sheela ve Deepa, 2013)	4	8054	3.9307	1.5289	1.2365	0.99886
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997)	6	15994	3.1459	1.5527	1.2461	0.99885
	(Zhang ve ark., 2003)	9	30000	2.0078	1.2103	1.1001	0.9991
	(Wong, 1991)	12	70000	1.8658	<b>1.0058</b>	<b>1.0029</b>	<b>0.99925</b>
	(Hunter ve ark., 2012)	63	60000	2.772	1.1446	1.0699	0.99915
	-	15	60000	<b>1.8031</b>	1.1323	1.0641	0.99916

#### 4.5 Beşinci Aday Giriş Değişkenleri Kümesine Ait Bulgular

Çizelge 4.5'te önerilen yöntem kullanılarak beşinci kümede yer alan aday giriş değişkenleri ile yapılan denemelerde en iyi performans değerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelge 4.5. Beşinci değişken kümesine ait performans değerleri

Giriş değişkenleri	Nöron sayısının hangi çalışma ile belirlendiği	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
AX <sub>1</sub> - AY <sub>1</sub> - AY <sub>2</sub> - BX <sub>1</sub> - BY <sub>1</sub> - BY <sub>2</sub> - Δx - Δy	(Shibata ve Ikeda, 2009)	3	10000	3.5966	1.687	1.2989	0.99875
	(Li ve ark., 1995)	4	10000	3.0899	1.5476	1.244	0.99885
	(Sheela ve Deepa, 2013)	5	10000	2.7611	1.4159	1.1899	0.99895
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997 )	8	17773	2.12	1.2877	1.1348	0.99904
	(Wong, 1991)	16	60000	2.003	1.1069	1.0521	0.99918
	(Zhang ve ark., 2003)	28	90000	2.4589	1.1871	1.0896	0.99912
	(Hunter ve ark., 2012)	255	20000	5.1924	2.3938	1.5472	0.99822
	-	<b>15</b>	<b>80000</b>	<b>1.7955</b>	<b>0.9915</b>	<b>0.9958</b>	<b>0.99926</b>

Çizelgede belirtilen denemelerden gizli katmanında 8 nöron bulunan YSA modeli ile yapılan denemede öğrenme algoritmasında kullanılan gradyan iniş değeri hedef değere ulaştığı için iterasyon belirlenen tekrardan daha önce tamamlanmıştır. Diğer nöron sayılarıyla; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılabilen denemelerden sadece en iyi performans değerlerine sahip iterasyona ait değerler çizelgeye yansıtılmıştır.

Bütün performans ölçütlerine ait değerler incelendiğinde; 15 nöron ve 60000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir.

#### 4.6 Altıncı Aday Giriş Değişkenleri Kümesine Ait Bulgular

Çizelge 4.6'da önerilen yöntem kullanılarak altıncı kümede yer alan aday giriş değişkenleri ile yapılan denemelerde en iyi performans değerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelge 4.6. Altıncı değişken kümesine ait performans değerleri

Giriş değişkenleri	Nöron sayısının hangi çalışma ile belirlendiği	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
AX <sub>1</sub> - AX <sub>2</sub> - BX <sub>1</sub> - BX <sub>2</sub> - Δx - Δy	(Shibata ve Ikeda, 2009)	2	1647	15.5293	8.9677	2.9946	0.99333
	(Li ve ark., 1995)	3	2505	4.3723	2.1298	1.4594	0.99842
	(Sheela ve Deepa, 2013)	4	4397	4.496	2.1597	1.4696	0.99839
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997)	6	6138	4.254	2.1421	1.4636	0.99841
	(Zhang ve ark., 2003)	9	13323	2.9889	1.5731	1.2543	0.99883
	(Wong, 1991)	12	10000	2.369	1.668	1.2915	0.99876
	(Hunter ve ark., 2012)	63	80000	3.4556	1.8298	1.3527	0.99864
	-	<b>15</b>	<b>100000</b>	<b>2.0412</b>	<b>1.1144</b>	<b>1.0556</b>	<b>0.99917</b>

Çizelgede belirtilen denemelerden gizli katmanlarında 2, 3, 4, 6 ve 9 nöron bulunan YSA modelleri ile yapılan denemelerde öğrenme algoritmasında kullanılan gradyan iniş değeri hedef değere ulaştığı için iterasyonlar belirlenen tekrardan daha önce tamamlanmıştır. Diğer nöron sayılarıyla; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılabilen denemelerden sadece en iyi performans değerlerine sahip iterasyona ait değerler çizelgeye yansıtılmıştır.

Bütün performans ölçütlerine ait değerler incelendiğinde; 15 nöron ve 100000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir.

#### **4.7 Yedinci Aday Giriş Değişkenleri Kümesine Ait Bulgular**

Çizelge 4.7'de önerilen yöntem kullanılarak yedinci kümede yer alan aday giriş değişkenleri ile yapılan denemelerde en iyi performans değerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelgede belirtilen denemelerden gizli katmanlarında 3 nöron bulunan YSA modeli ile yapılan denemede öğrenme algoritmasında kullanılan gradyan iniş değeri hedef değere ulaştığı için iterasyon belirlenen tekrardan daha önce tamamlanmıştır. Diğer nöron sayılarıyla; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılabilen denemelerden sadece en iyi performans değerlerine sahip iterasyona ait değerler çizelgeye yansıtılmıştır.

Bütün performans ölçütlerine ait değerler incelendiğinde; 15 nöron ve 90000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir.

Çizelge 4.7. Yedinci deęişken kümesine ait performans deęerleri

Giriş deęişkenleri	Nöron sayısının hangi çalışma ile belirlendięi	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
$AX_1 - AX_2 -$ $AY_1 - BX_1 -$ $BX_2 - BY_1 -$ $\Delta x - \Delta y$	(Shibata ve Ikeda, 2009)	3	4098	4.9484	1.7608	1.327	0.99869
	(Li ve ark., 1995)	4	20000	2.5255	1.2953	1.1381	0.99904
	(Sheela ve Deepa, 2013)	5	30000	2.5521	1.4817	1.2173	0.9989
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997 )	8	50000	2.1012	1.2929	1.137	0.99904
	(Wong, 1991)	16	100000	1.9268	1.2775	1.1303	0.99905
	(Zhang ve ark., 2003)	28	90000	2.1913	1.1029	1.0502	0.99918
	(Hunter ve ark., 2012)	255	20000	5.0127	1.9535	1.3977	0.99855
	-	<b>15</b>	<b>90000</b>	<b>1.6961</b>	<b>0.9667</b>	<b>0.9832</b>	<b>0.99928</b>

#### 4.8 Sekizinci Aday Giriş Deęişkenleri Kümesine Ait Bulgular

Çizelge 4.8’de önerilen yöntem kullanılarak sekizinci kümede yer alan aday giriş deęişkenleri ile yapılan denemelerde en iyi performans deęerlendirme sonuçlarını veren YSA modellerine ait bilgiler yer almaktadır.

Çizelgede belirtilen denemelerden gizli katmanlarında 3 ve 4 nöron bulunan YSA modelleri ile yapılan denemelerde öğrenme algoritmasında kullanılan gradyan iniş deęeri hedef deęere ulaştığı için iterasyonlar belirlenen tekrardan daha önce tamamlanmıştır. Dięer nöron sayılarıyla; 10000, 20000, 30000, 40000, 50000, 60000, 70000, 80000, 90000, 100000 iterasyonlar için yapılabilen denemelerden sadece en iyi performans deęerlerine sahip iterasyona ait deęerler çizelgeye yansıtılmıştır.

Çizelge 4.8. Sekizinci değişken kümesine ait performans değerleri

Giriş değişkenleri	Nöron sayısının hangi çalışma ile belirlendiği	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
$AX_1 - AX_2 -$ $AY_1 - AY_2 -$ $BX_1 - BX_2 -$ $BY_1 - BY_2 -$ $\Delta x - \Delta y$	(Shibata ve Ikeda, 2009)	3	7376	4.4311	1.7748	1.3322	0.99868
	(Li ve ark., 1995; Sheela ve Deepa, 2013)	4	7930	4.098	1.6026	1.2659	0.99881
	(Tang ve Fishwick, 1993; Tamura ve Tateishi, 1997)	10	60000	2.1242	1.0565	1.0278	0.99921
	(Wong, 1991)	20	80000	2.0211	1.0828	1.0406	0.99919
	(Zhang ve ark., 2003)	93	20000	3.5517	1.515	1.2309	0.99887
	(Hunter ve ark., 2012)	1023	20000	5.8862	2.1683	1.4725	0.99839
	-	<b>15</b>	<b>60000</b>	<b>1.9509</b>	<b>1.0266</b>	<b>1.0132</b>	<b>0.99924</b>

Bütün performans ölçütlerine ait değerler incelendiğinde; 15 nöron ve 60000 iterasyon ile yapılan denemenin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan denemelerden daha iyi sonuç verdiği görülmektedir.

#### 4.9 Belirlenen YSA Modeline Ait Bulgular

Çizelge 4.9’da, daha önce belirlenmiş olan aday giriş değişkeni kümelerine ait deneme bulgularından en iyi performans değerlendirme sonuçlarını veren YSA modellerinin bazı performans değerlendirme ölçütlerine ait değerleri yer almaktadır.

Çizelge 4.9. Giriş değişkeni kümelerinin en iyi sonucu veren denemeleri

Giriş değişkenleri kümesi	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
$AX_1 - BX_1 - \Delta x$	15	60000	2.816	1.8687	1.367	0.99861
$AX_1 - AX_2 - BX_1 - BX_2 - \Delta x$	15	20000	2.7238	2.3572	1.5353	0.99825
$AX_1 - BX_1 - \Delta x - \Delta y$	15	90000	3.1983	1.6701	1.2923	0.99876
$AX_1 - AY_1 - BX_1 - BY_1 - \Delta x - \Delta y$	15	60000	1.8031	1.1323	1.0641	0.99916
$AX_1 - AY_1 - AY_2 - BX_1 - BY_1 - BY_2 - \Delta x - \Delta y$	15	80000	1.7955	0.99152	0.99575	0.99926
$AX_1 - AX_2 - BX_1 - BX_2 - \Delta x - \Delta y$	15	100000	2.0412	1.1144	1.0556	0.99917
<b><math>AX_1 - AX_2 - AY_1 - BX_1 - BX_2 - BY_1 - \Delta x - \Delta y</math></b>	<b>15</b>	<b>90000</b>	<b>1.6961</b>	<b>0.96668</b>	<b>0.9832</b>	<b>0.99928</b>
$AX_1 - AX_2 - AY_1 - AY_2 - BX_1 - BX_2 - BY_1 - BY_2 - \Delta x - \Delta y$	15	60000	1.9509	1.0266	1.0132	0.99924

Değerlendirmeler aday giriş değişkeni kümesine ait bulgulardaki MAPE değerleri dikkate alınarak yapılmıştır. Çizelge 4.9’da aday giriş değişkenleri kümesiyle yapılan denemelerin her birinden en iyi MAPE değerine sahip modele ait bulgular yer almaktadır.

Çizelge 4.9’da yer alan bilgilere göre; bütün aday giriş değişkeni kümeleriyle yapılan denemelerde deneme yanılma yoluyla belirlenen 15 nöron ile yapılan denemelerin literatürde yer alan çalışmalardaki nöron sayısı hesaplama denklemleri ile belirlenen nöron sayılarıyla yapılan diğer denemelerden daha iyi sonuç verdiği görülmektedir.

Giriş değişkenleri, nöron sayısı ve iterasyon sayısını belirlemek için yapılan ilk denemeler sonucunda en iyi performans değerleri;  $AX_1$ ,  $AX_2$ ,  $AY_1$ ,  $BX_1$ ,  $BX_2$ ,  $BY_1$ ,  $\Delta x$  ve  $\Delta y$  giriş değişkenlerine sahip, gizli katmanında 15 nöron bulunan ve eğitimi 90000 iterasyon ile gerçekleştirilen YSA modeli ile elde edilmiştir. Bu model ile elde edilen MAPE, MSE, RMSE ve R performans ölçütlerine ait değerlerin Çizelge 4.9’da yer alan diğer bütün modellerden daha iyi olduğu görülmektedir.

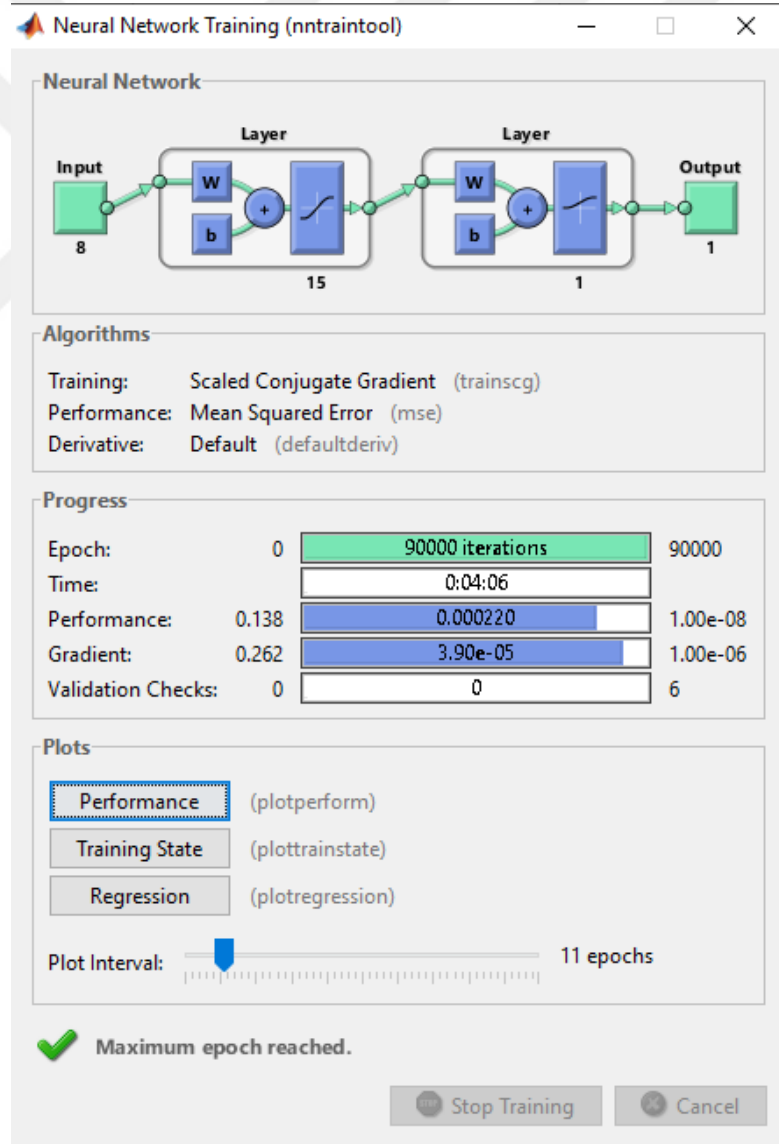
Denemeler sonucunda bulunan en iyi hata değerine sahip YSA modeli, iterasyon sayısı 1000’er azaltılarak 9 defa ve 1000’er artırılarak 9 defa olmak üzere 18 kez daha denenmiştir. Belirtilen denemelerde elde edilen performans ölçütlerine ait değerler Çizelge 4.10’da yer almaktadır.

Çizelge 4.10. Belirlenen YSA modeli ile iterasyon sayısının araştırılması

Giriş değişkenleri kümesi	Nöron sayısı	İterasyon sayısı	MAPE	MSE	RMSE	R
$AX_1 - AX_2 - AY_1 - BX_1 - BX_2 - BY_1 - \Delta x - \Delta y$	15	81000	2.3186	1.2231	1.1059	0.99909
		82000	1.8913	1.2368	1.1121	0.99908
		83000	3.3933	1.4196	1.1915	0.99894
		84000	3.3173	1.3553	1.1642	0.99899
		85000	2.4144	<b>0.95586</b>	<b>0.97768</b>	<b>0.99929</b>
		86000	1.8495	1.0863	1.0423	0.99919
		87000	1.9637	0.97652	0.98819	0.99927
		88000	2.2730	1.0902	1.0441	0.99919
		89000	2.7866	1.0855	1.0419	0.99919
		<b>90000</b>	<b>1.6961</b>	0.96668	0.9832	0.99928
		91000	2.5104	1.2940	1.1375	0.99904
		92000	1.9900	1.0046	1.0023	0.99925
		93000	2.5372	1.0434	1.0215	0.99922
		94000	2.2933	1.0374	1.0185	0.99923
		95000	6.4784	2.1105	1.4528	0.99843
		96000	2.3996	1.7513	1.3234	0.99870
		97000	2.6015	1.3674	1.1693	0.99898
98000	2.2022	1.0761	1.0373	0.99920		
99000	2.3597	1.1897	1.0907	0.99912		

MAPE değerleri dikkate alındığında önerilen yöntem ile bütün denemelerden elde edilen performans değerlendirme sonuçları arasında en başarılı performans değerlerine  $AX_1 - AX_2 - AY_1 - BX_1 - BX_2 - BY_1 - \Delta x - \Delta y$  giriş değişkenlerine sahip, gizli katmanında 15 nöron bulunan ve 90000 iterasyon ile eğitilen YSA modeli ile ulaşıldığı belirlenmiştir. MSE, RMSE ve R değerlerine göre  $AX_1 - AX_2 - AY_1 - BX_1 - BX_2 - BY_1 - \Delta x - \Delta y$  giriş değişkenlerine sahip, gizli katmanında 15 nöron bulunan model en iyi performansa 85000 iterasyon sonucunda ulaşmıştır.


MAPE değerleri dikkate alındığında denemelerde belirlenen en iyi performansa sahip YSA modeline ait gösterim Şekil 4.1’de yer almaktadır.



Şekil 4.1. Belirlenen YSA modeline ait bilgiler

Şekil 4.1 ile gösterilen YSA modelinde; gizli katmanlarda bulunan nöronlarda “Hiperbolik Tanjant” aktivasyon fonksiyonu, çıktı katmanında bulunan nöronda “Sigmoid” aktivasyon fonksiyonu ve öğrenme algoritması olarak Ölçeklenmiş Eşlenik Eğim (Scaled Conjugate Gradient) algoritması kullanıldığı görülmektedir.

Şekil 4.2’de Matlab programıyla YSA eğitimi sonucunda elde edilen korelasyon grafiği bulunmaktadır. Grafikte tahmin değerleri ve gerçek değerler arasındaki korelasyon katsayısının 0.99855 değerine sahip olduğu görülmektedir. Çizelge 4.11’de test verileriyle üretilen YSA çıktılarına ait veriler yer almaktadır. Çizelgede sırasıyla test verilerine ait sıralama ve gerçek değerler ile YSA çıktı değerlerine ait veriler bulunmaktadır.

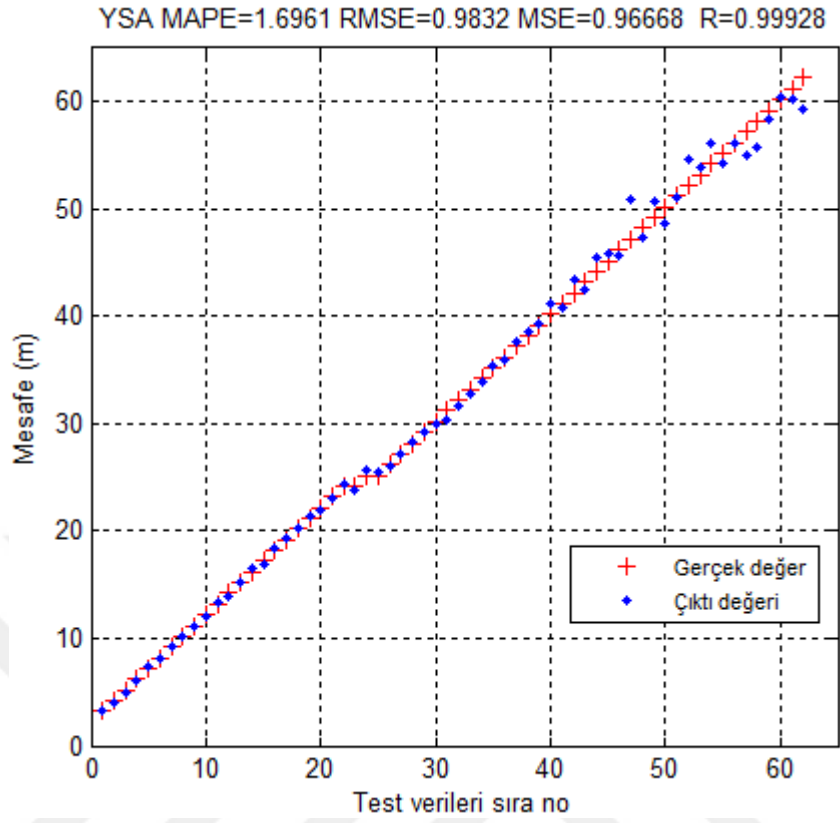


Şekil 4.2. YSA eğitimi ile elde edilen korelasyon grafiği

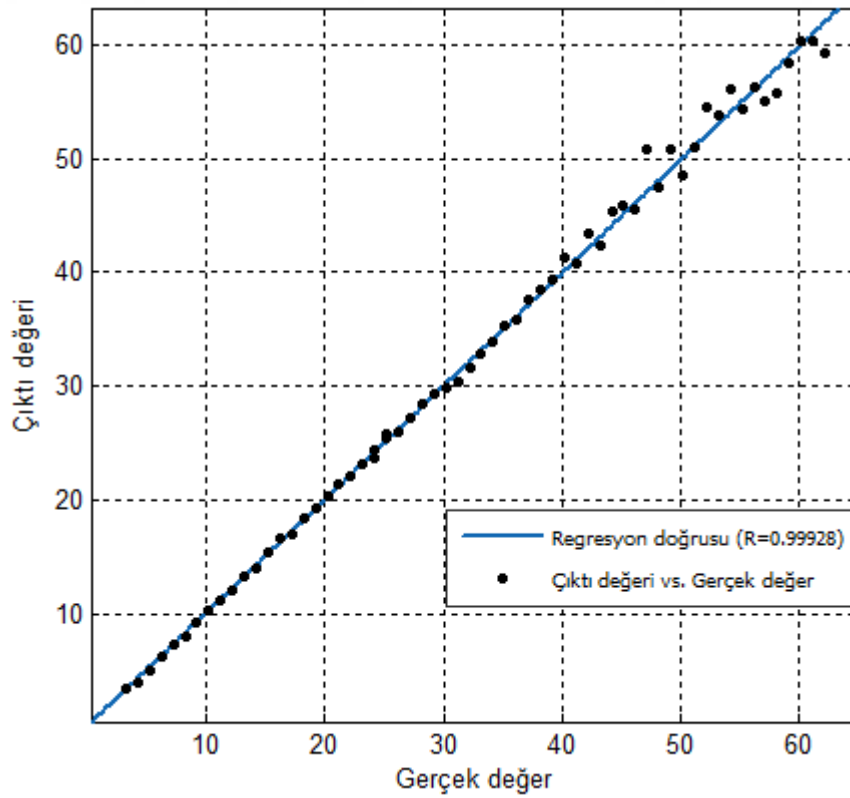
Çizelge 4.11. Test verilerine ait YSA çıktı değerleri

Veri No	Değer	Çıktı	Veri No	Değer	Çıktı	Veri No	Değer	Çıktı
1	3.2	3.3420	22	24.2	24.3741	43	43.2	42.4220
2	4.2	3.9742	23	24.2	23.7554	44	44.2	45.4467
3	5.2	5.0353	24	25.2	25.7624	45	45.2	45.8414
4	6.2	6.1588	25	25.2	25.4497	46	46.2	45.6004
5	7.2	7.3033	26	26.2	25.9955	47	47.2	50.9121
6	8.2	8.0581	27	27.2	27.2059	48	48.2	47.4223
7	9.2	9.2674	28	28.2	28.3465	49	49.2	50.7930
8	10.2	10.2319	29	29.2	29.3029	50	50.2	48.6208
9	11.2	11.1263	30	30.2	29.9074	51	51.2	51.0216
10	12.2	12.0340	31	31.2	30.3951	52	52.2	54.6016
11	13.2	13.2811	32	32.2	31.5736	53	53.2	53.8518
12	14.2	13.9779	33	33.2	32.8274	54	54.2	56.0523
13	15.2	15.3076	34	34.2	33.9366	55	55.2	54.3387
14	16.2	16.6027	35	35.2	35.3809	56	56.2	56.2068
15	17.2	16.9883	36	36.2	35.8843	57	57.2	54.9853
16	18.2	18.3317	37	37.2	37.6161	58	58.2	55.6832
17	19.2	19.2654	38	38.2	38.5715	59	59.18	58.4052
18	20.2	20.2921	39	39.2	39.3279	60	60.2	60.4038
19	21.2	21.3049	40	40.2	41.2263	61	61.2	60.2921
20	22.2	22.0011	41	41.2	40.7557	62	62.2	59.2255
21	23.2	23.1461	42	42.2	43.3768			

Şekil 4.3'te test verilerine ait YSA çıktı değerleri ile gerçek değerleri içeren grafik ve YSA çıktı değerleri için bazı performans ölçütlerine ait bilgiler yer almaktadır. Grafikte yer alan yatay ekseninde verilerin sıralanışına ait bilgiler, dikey ekseninde ise mesafe bilgileri yer almaktadır. Belirtilen YSA modelinin test verileriyle elde edilen çıktı değerlerine ait MAPE değeri 1.6961, RMSE değeri 0.9832 ve MSE değeri 0.96668 olarak belirlenmiştir. Şekil 4.4'te test verilerine ait YSA tahmin değerleri ile gerçek değerler arasındaki ilişki görülmektedir. Test verilerine ait YSA çıktı değerleri ile gerçek değerler arasındaki korelasyon katsayısı değeri 0.99928 olarak hesaplanmıştır.



Şekil 4.3. Test verilerine ait YSA çıktıları ve gerçek değerler



Şekil 4.4. YSA çıktısı ve gerçek değerler arasındaki ilişki

## 5. TARTIŞMA ve SONUÇ

Bu tez çalışmasında, optik eksenleri birbiriyle kesişen iki kameradan alınan görüntüleri kullanan araçtan araca mesafe tahmin yöntemi sunulmaktadır. Önerilen yöntem öndeki aracın belirlenen bir hedef noktasının stereo kamera görüntülerindeki konum değerleri arasında olan eşitsizlikten yararlanarak YSA ile mesafe tahmini yapmaktadır. Çalışmada yatay bir platforma yerleştirilen iki kameranın yönü belirli bir açıyla ve eşit oranda birbirlerine doğru döndürülerek optik eksenlerinin kesişmeleri sağlanmıştır. Yapılan hesaplamalarda, optik eksenleri kesişen iki kameranın görüntülerinde yer alan hedef noktada meydana gelen yatay kaymanın kameraların hedef noktaya olan optik eksen uzaklıklarını değiştirerek birbirinden farklı değerler almasını sağladığı belirlenmiştir. Optik eksenlerin hedef noktaya olan uzaklıklarının değişerek farklı değerler alması  $\Delta x$  değerlerinde değişikliğe neden olmaktadır. Bu sebepten ötürü, bu çalışmada mesafesi belirlenecek nesnenin yatay kayma değerleri mesafe tahmininde dikkate alınmaktadır. Ashoori ve Mahlouji (2017); kameralardan bir tanesinin yönünü diğer kameraya doğru döndürerek optik eksenlerinin kesişmelerini sağladıkları iki kamerayla gerçekleştirdikleri denemelerin mesafe tahmin sonuçlarından elde ettikleri bilgilerden yola çıkarak, hedef nesnenin yatay yönde meydana gelen kaymalarının mesafe tahmin sonuçlarını etkilediğini ifade etmiştir.  $\Delta x$  değerini etkileyen bir başka faktör ise aracın üzerinde bulunduğu yolun zeminine bağlı olarak meydana gelen, hedef noktanın kameraların görüntülerindeki dikey konum farklılığıdır. Zeminin eğimine bağlı olarak kameraların üzerinde bulunduğu platformda meydana gelen dairesel dönme kamera görüntülerindeki dikey konum değerleri ile birlikte yatay konum değerlerini değiştirir. Dolayısıyla mesafe tahmini için oluşturulan YSA modelinde kullanılan giriş değerleri arasında öndeki aracın belirlenen hedef noktasının kamera görüntülerindeki yatay konum değerlerine ait bilgileri ile birlikte dikey konum değerlerine ait bilgileri kullanılmalıdır.

Çalışmada; optik eksenleri birbirine doğru eğimli stereo kamera modelinin farklı eğim açılarıyla ve optik eksenlerin eğim açısına sahip olmadığı paralel stereo kamera modeliyle elde edilen,  $\Delta x$  faktörünün belirlemiş olduğu hata toleransları oluşturulan

grafikler vasıtasıyla karşılaştırılmaktadır. 1.5 m kayma değerine kadar olan farklı kayma değerleri için oluşturulan grafiklerden elde edilen karşılaştırma sonuçlarına göre, optik eksen eğim açılarının artması mesafe tahmininde büyük oranda avantaj sağlamaktadır. Katada ve ark. (2014); optik eksenleri birbirine doğru eğimli stereo kamera modeli ile optik eksenleri paralel geleneksel stereo kamera modelini üçgenleme yöntemi kullanarak elde ettiği mesafe tahmin sonuçlarına göre karşılaştırmaktadır. Yapılan karşılaştırmaya göre optik eksenleri birbirine doğru eğimli olan stereo kamera modelinin daha başarılı olduğu ifade edilmektedir.

Bu tez çalışmasında; stereoskopik kameralar ile öndeki aracın mesafesini belirlemeye yönelik literatürde yer alan diğer çalışmalardan farklı olarak, oluşturulan bir YSA modeli ile mesafe tahmini yapılmaktadır. Önerilen yöntemde mesafe tahminine YSA ile çözüm aranması bazı avantajlar sağlamaktadır. Simpson (1990)'a göre YSA'lar hata toleransına sahiptirler. Eksik veya hatalı bilgiler içeren örnek veri setleriyle bile çalışabilirler. Ayrıca uygun nitelikte ve sayıda veriler kullanıldığında güvenilirliği yüksek sonuçlar elde edilebilmektedir (Kaftan, 2010).

Çalışmada YSA modelinde kullanılacak veri setini oluşturmak için elde edilen 414 örnek görüntü çiftinden 352 tanesi eğitim veri seti, 62 tanesi ise test veri seti için kullanılmıştır. Veri setini oluşturmak amacıyla bir aracın 60 metreye kadar olan uzaklıklarından 1'er metre aralıklarla alınan görüntülerinin yanında belirlenen her uzaklığı için farklı yatay kayma değerlerindeki görüntülerinden örnekler alınmıştır. Bu yolla öndeki aracın farklı uzaklıklarının yanında farklı yatay kaymaları YSA eğitiminde dikkate alınmaktadır. Ayrıca bu şekilde veri setinde kullanılan örnek sayısının artırılarak daha güvenilir sonuçlar elde edilmesi sağlanmıştır. Sönmez Çakır (2019) tarafından bildirildiğine göre; bir YSA ile güvenilir sonuçlar elde etmek için veri setinde yeterli sayıda örnek bulunması gerekmektedir. YSA modelinde kullanılacak giriş değişkenlerinin araştırılması için öncelikle aday giriş değişkenleri belirlenmektedir. Aday giriş değişkenlerinin belirlenmesi için; görüntü örneklerinden elde edilen, iki kamera görüntüsündeki tespit edilen öndeki araç plaka bölgesi merkez noktasının koordinat bilgilerinden yararlanılmıştır. Giriş değişkenlerinin araştırılması amacıyla denemeler yapılmıştır. Yapılan denemeler sonucunda en iyi sonucu veren YSA modelinin giriş değişkenleri belirlenmiştir. Bunlar; iki kamera görüntüsündeki

hedef noktanın sađ ve sol kenarlardan uzaklıkları, iki kamera görüntüsündeki hedef noktanın üst kenardan uzaklıkları, hedef noktanın iki kamera görüntüsü arasındaki yatay piksel konum farkı ve hedef noktanın iki kamera görüntüsü arasındaki dikey piksel konum farkından oluşmaktadır. En iyi sonucu veren giriş değişkenleri içerisinde yatay piksel konum bilgileriyle belirlenen değişkenlerin yanında dikey piksel konum bilgileriyle belirlenen değişkenler de bulunmaktadır. Bu durum, öndeki aracın iki kamera görüntüsündeki dikey konum farklılığının kamera görüntüsü içerisindeki yatay konum bilgilerini etkilediğini göstermektedir.

Bir sınırlama olarak görüntü örneklerinden plaka bölgelerinin tespiti manuel olarak yapılmıştır. Bu duruma bađlı olarak çalışmada kullanılan metodolojinin değerlendirilmesi plaka bölgesinin tespitinden bađımsız olarak gerçekleştirilmiştir. Bununla birlikte, çalışmada elde edilen performans değerlendirme sonuçlarının başarı oranı oldukça yüksektir. Elde edilen sonuçlar önerilen kamera modeli ve geliştirilen YSA modeliyle oluşturulan metodolojinin, ön araca ait plaka bölgesinin veya herhangi bir hedef bölgenin etkili bir biçimde tespit edilebilmesine bađlı olarak etkin bir biçimde kullanılabilir olduğunu göstermektedir.

Denemeler sonucunda elde edilen en iyi performans değerlerine sahip YSA modelinin eğitim verilerine ait tahmin sonuçları ile gerçek değerler arasındaki korelasyon katsayısı değeri 0.99855 olarak belirlenmiştir. YSA eğitimi sonunda Matlab programı ile elde edilen saçılım grafiğinde yer alan lineer doğrunun değişkenler arasındaki bađıntıyı tanımlamada oldukça başarılı olduğu görülmektedir.

En iyi performansa sahip YSA modelinin test verileriyle elde edilen mesafe tahmin değerleri ve mesafelerin ölçülen gerçek değerleri arasındaki korelasyon katsayısı değeri 0.99928 olarak hesaplanmıştır. Oluşturulan saçılım grafiğinde yer alan lineer doğrunun değişkenler arasındaki bađıntıyı tanımlamada oldukça başarılı olduğu görülmektedir. Büyüköztürk ve ark. (2009)'a göre değişkenler arası ilişki; korelasyon katsayısı değeri 0.3'ten küçük ise "düşük seviyeli", 0.3 ile 0.7 arasında ise "orta seviyeli" ve 0.7'den büyük ise "yüksek seviyeli" olarak nitelendirilebilir (Güler ve Taşdelen Teker, 2015). Bu tanımlamaya göre; elde edilen 0.99928 korelasyon katsayısı değeri, test verilerine ait

YSA çıktı değerleri ile mesafelerin ölçülen gerçek değerleri arasındaki ilişkinin “yüksek seviyeli” olarak nitelendirilebilir olduğunu göstermektedir.

Test verileriyle yapılan YSA denemelerinde elde edilen mesafe tahmin sonuçlarına göre en iyi performans değerlerine sahip YSA modelinin MAPE değeri %1.6961 olarak belirlenmiştir. Lewis (1982); yapmış olduğu çalışmada MAPE değeri %10 değerinin altında olan YSA modellerini “çok iyi”, %10 ile %20 değerleri arasında olan modelleri “iyi”, %20 ile %50 değerleri arasında olan modelleri “kabul edilebilir” ve %50’den daha yüksek değerlere sahip modelleri ise “hatalı” olarak değerlendirmiştir. Bu değerlendirmeye göre; elde edilen %1.6961 MAPE değeri, YSA modelinin “çok iyi” olarak nitelendirilebilir olduğunu göstermektedir.

Önerilen yöntem ile test verilerinden elde edilen mesafe tahmin sonuçları incelendiğinde öndeki aracın 40 m uzaklığına kadar olan mesafe tahmin sonuçlarının daha uzak mesafelere kıyasla daha iyi değerlere sahip olduğu görülmektedir. Önerilen yöntemde uzak mesafelerde yatay uzaklıkların kamera görüntülerindeki piksel sayısı cinsinden miktarı azalacağından araçların yatay kaymalarına bağlı olan piksel konum farkları arasındaki değişim miktarı da azalmaktadır. Bu sebepten ötürü, önerilen yöntemde öndeki aracın kamera görüntülerindeki piksel konum farkından yararlandığı için uzak mesafelerde mesafe tahminindeki hata toleransının düşeceği düşünülmektedir. Uzak mesafelerdeki hata toleransını düşüren bir diğer faktör plaka bölgesini tespit etme güçlüğüdür. Önerilen yöntemde mesafe tahmini için öndeki aracın plaka bölgesinin merkez noktasının iki kamera görüntüsündeki konum bilgilerinden yararlanılmaktadır. Plaka bölgesinin kamera görüntülerindeki yerlerinin doğru bir şekilde tespit edilememesi elde edilen sonuçlarda hata oranının artmasına neden olmaktadır. Uzak mesafelerde bulunan plaka bölgelerinin kamera görüntüleri üzerinde kapladığı alanlar küçüleceğinden tespit edilmeleri yakın mesafelere kıyasla daha zor olmaktadır. Kullanılan kameraların donanımsal özellikleri ve ortam aydınlatmasının çok fazla veya çok düşük olması gibi faktörler görüntüler üzerindeki plaka bölgesinin tam olarak tespit edilememesine yol açabilmektedir. Bu çalışmada görüntülerde yer alan plaka bölgelerinin tespiti manuel olarak yapılmıştır. İleriki çalışmalarda gelişen teknolojiye paralel olarak kameralarda kullanılan donanımsal özelliklerin gelişmesiyle birlikte plaka bölgesinin tespiti daha etkili bir şekilde gerçekleştirilebilir.

## 6. KAYNAKLAR

- Akar, F., 2009. Şablon Eşleme Yöntemi ile Plaka Tanıma ve Değerlendirme Sistemi. (Doktora Tezi), Atatürk Üniversitesi Fen Bilimleri Enstitüsü / Matematik Ana Bilim Dalı, Erzurum.
- Aktaş, R., 2003. Mali başarısızlığın öngörülmesi: İstatiksel yöntemler ve yapay sinir ağı karşılaştırılması. Ankara Üniversitesi SBF Dergisi, 50(04), 1-24.
- Alizadeh, P. ve Zeinali, M., 2013. A real-time object distance measurement using a monocular camera. Proceedings of the Lasted International Conference Modelling and Simulation, Canada.
- Ashoori, M. E. ve Mahlouji, M., 2017. Measuring the distance between the two vehicles using stereo vision with optical axes cross. Modern Applied Science, 12(1), 165-180.
- Asif, M.R., Qi, C., Tiexiang, W., Fareed, M.S. ve Raza, S.Y., 2019. License plate detection for multi-national vehicles: An illumination invariant approach in multi-lane environment. Computers and Electrical Engineering, 78(2019), 132-147.
- Ataseven, B., 2013. Yapay sinir ağları ile öngörü modellemesi. Öneri, 10(39), 101-115.
- Aydemir, Ö. ve Kayıkçıoğlu, T., 2009. EEG tabanlı beyin bilgisayar arayüzleri. Akademik Bilişim 2009, Harran Üniversitesi, Şanlıurfa.
- Bakkaloğlu, A., 2011. Araç Plaka Tanıma Sistemi. (Y.Lisans Tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü / Bilgisayar Mühendisliği Ana Bilim Dalı, Konya.
- Bas, E., 2007. Road and Traffic Analysis form Video. (Y.Lisans Tezi), Koç Üniversitesi Elektrik ve Bilgisayar Mühendisliği, İstanbul.
- Bayır, F., 2006. Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama. (Y.Lisans Tezi), İstanbul Üniversitesi Sosyal Bilimler Enstitüsü / İşletme Ana Bilim Dalı Sayısal Yöntemler Bilim Dalı, İstanbul.
- Bertozzi, M., Broggi, A., Fascioli, A. ve Nichele, S., 2000. Stereo vision-based vehicle detection. Proceedings of the IEEE Intelligent Vehicles Symposium 2000 (Cat. No.00TH8511), Dearborn, MI, USA.
- Bora, K., 2009. Car Plate Recognition. (Y.Lisans Tezi), Atılım Üniversitesi / Bilgisayar Mühendisliği Ana Bilim Dalı, Ankara.
- Buckland, M. ve Collins, M., 2002. AI Techniques for Game Programming. Cengage Learning PTR, 480 p, Cincinnati, Ohio, USA.
- Büyüköztürk, Ş., Çokluk, Ö. ve Kök, N., 2009. Sosyal Bilimler için İstatistik. Pegem Akademi, 263 s, Ankara.
- Çamaşırıcıoğlu, E., 2007. Araç Plakası Algılama ve Tanıma. (Y.Lisans Tezi), Ankara Üniversitesi Fen Bilimleri Enstitüsü / Elektronik Mühendisliği Ana Bilim Dalı, Ankara.
- Chang, J. Y. ve Cho, C. W., 2006. Vision-based front vehicle detection and its distance estimation. IEEE International Conference on Systems, Man and Cybernetics, Taipei, Taiwan.
- Demuth, H. ve Beale, M., 2004. Neural Network Toolbox: for use with MATLAB (Version 4.0). The MathWorks. Inc., Massachusetts, USA.

- Doğan, E., Ateş, A., Yılmaz, E. C. ve Eren, B., 2008. Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand. *Environmental Progress*, 27(4), 439-446.
- Durak, A., 2012. Konvektif Bir Kurutma Prosesinin Yapay Sinir Ağı ile Modellenmesi. (Y.Lisans Tezi), Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü / Makine Mühendisliği Ana Bilim Dalı, Tekirdağ.
- Efe, M.Ö. ve Kaynak, O., 2004. Yapay Sinir Ağları ve Uygulamaları. Boğaziçi Üniversitesi, 141 s, İstanbul.
- Emani, S., Soman, K. P., Variyar, S. V. V. ve Adarsh, S., 2019. Obstacle detection and distance estimation for autonomous electric vehicle using stereo vision and DNN. *Soft Computing and Signal Processing. Advances in Intelligent Systems and Computing*, vol 898, Wang, J., Reddy, G., Prasad, V., Reddy, V. (eds.). Springer, Singapore, 639-648.
- Ersoy, E. ve Karal, Ö., 2012. Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimleri Araştırma Dergisi*, 1(2), 188-205.
- Fathi, H. ve Brilakis, I., 2014. A multi-step explicit stereo camera calibration approach to improve euclidean accuracy of large-scale 3D reconstruction, *Journal of Computing in Civil Engineering*, 30(1), 04014120.
- Gonzales, R. C. ve Woods, R. E., 2008. *Digital Image Processing (Third Edition)*. Pearson Education, 954, New Jersey.
- Goodall, N. J., 2014. Ethical decision making during automated vehicle crashes. *Transportation Research Record*, 2424(1), 58-65.
- Göçerler, B., 2015. Yapay Zeka Tabanlı Plaka Tanıma ile Bariyer Kontrolü. (Y.Lisans Tezi), Trakya Üniversitesi Fen Bilimleri Enstitüsü / Bilgisayar Mühendisliği Ana Bilim Dalı, Edirne.
- Graupe, D., 2013. *Principles of Artificial Neural Networks*. World Scientific, 384 p, Singapore.
- Gurney, K., 1996. *Computers and symbols versus nets and neurons*. UCL Draft Papers, No:1, U.K.
- Güler, N. ve Taşdelen Teker, G., 2015. Açık uçlu maddelerde farklı yaklaşımlarla elde edilen puanlayıcılar arası güvenirliliğin değerlendirilmesi. *Journal of Measurement and Evaluation in Education and Psychology*, 6(1), 12-24.
- Han, J., Heo, O., Park, M., Kee, S. ve Sunwoo, M., 2016. Vehicle distance estimation using a mono-camera for FCW/AEB systems. *International Journal of Automotive Technology*, 17, 483-491.
- Häne, C., Sattler, T. ve Pollefeys, M., 2015. Obstacle detection for self driving cars using only monocular cameras and wheel odometry. 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Hamburg, Germany.
- Haykin, S., 1999. *Neural Networks*. Prentice Hall International, 842, New Jersey, USA.
- Hou, A., Cui, X., Geng, Y., Yuan, W. ve Hou, J., 2011. Measurement of Safe Driving Distance Based on Stereo Vision. 2011 Sixth International Conference on Image and Graphics, Hefei, Anhui, China.
- Hsu, T. ve Wang, T., 2015. An improvement stereo vision images processing for object distance measurement. *International Journal Of Automation And Smart Technology*, 5(2), 85-90.
- Huang, D. Y., Chen, C. H., Chen, T. Y., Hu, W. C. ve Feng, K. W., 2017. Vehicle detection and inter-vehicle distance estimation using single-lens

- video camera on urban/suburb roads. *Journal of Visual Communication and Image Representation*, 46, 250-259.
- Huh, K., Park, J., Hwang, J. ve Hong, D., 2008. A stereo vision-based obstacle detection system in vehicles. *Optics and Lasers in Engineering*, 46(2), 168-178.
- Hunter, D., Yu, H., Pukis, M., Kolbusz, J. ve Wilamowski, B., 2012. Selection of proper neural network sizes and architectures: A comparative study. *IEEE Transactions on Industrial Informatics*, 8(2), 228-240.
- Irmakçı, İ., 2008. Otomatik Araç Plaka Tanıma Sistemi. (Y.Lisans Tezi), Ege Üniversitesi Fen Bilimleri Enstitüsü / Elektrik Elektronik Mühendisliği Ana Bilim Dalı, İzmir.
- Irmisch, P., 2017. Camera-based distance estimation for autonomous vehicles. (Y.Lisans Tezi), Technical University Berlin, Berlin.
- Ito, T., Sakagami, T. ve Kawakatsu, S., 1992. A real time distance headway measurement method using stereo and optical flow. *Proceedings of the Intelligent Vehicles '92 Symposium*, Detroit, United States.
- Jähne, B., 2005. *Digital Image Processing*. Springer, 607, Berlin, Heidelberg.
- Kaftan, İ., 2010. Batı Türkiye Gravite ve Deprem Katalog Verilerinin Yapay Sinir Ağları ile Değerlendirilmesi. (Doktora Tezi), Dokuz Eylül Üniversitesi. Fen Bilimleri Enstitüsü, İzmir.
- Karayolları Trafik Yönetmeliği (1997), T. C. Resmi Gazete, 23053, 18 Temmuz 1997.
- Katada, K., Shenjing, C. ve Lifeng, Z., 2014. The triangulation of toe-in style stereo camera. *Proceedings of the 2nd International Conference on Intelligent Systems and Image Processing 2014*.
- Kehtarnavaz, N., Griswold, N. C. ve Eem, J. K., 1991. Comparison of mono and stereo-camera systems for autonomous vehicle tracking. *Proc. SPIE 1468, Applications of Artificial Intelligence IX*, Orlando, FL, United States.
- Kısa, M., 2014. Karayolunda Seyreden Araçların Tanınması. (Doktora Tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü / Makine Mühendisliği Ana Bilim Dalı, Konya.
- Kim, G. ve Cho, J. S., 2012. Vision-based vehicle detection and inter-vehicle distance estimation for driver alarm system. *Optical Review*, 19(6), 388-393.
- Kormann, B., Neve, A., Klinker, G. ve Stechele, W., 2010. Stereo vision based vehicle detection. *VISAPP 2010 – Proceedings of the International Conference on Computer Vision Theory and Applications*, 2, 431-438.
- Lalimi, M.A., Ghofrani, S. ve Maclernon, D., 2013. A vehicle license plate detection method using region and edge based methods. *Computers and Electrical Engineering*, 39(3), 834-845.
- Lawrence, R., 1997. Using neural networks to forecast stock market prices. Department of Computer Science University of Manitoba.
- Leu, A., Aiteanu, D. ve Gräser, A., 2011. A novel stereo camera based collision warning system for automotive applications. *6th IEEE International Symposium on Applied Computational Intelligence and Informatics*, Timișoara, Romania.
- Li, J. Y., Chow, T. W. S. ve Yu, Y.L., 1995. The estimation theory and optimization algorithm for the number of hidden units in the higher-order feedforward neural network. *Proceedings of ICNN'95 – International Conference on Neural Networks*, Perth, WA, Australia.
- Li, Y., Chen, P. ve Zhang, M., 2016. The vehicle distance measurement system based on binocular stereo vision. *Proceedings of the 2015 International Conference on*

- Electrical and Information Technologies for Rail Transportation, Zhuzhou, China.
- Lim, B., Woo, T. ve Kim, H., 2017. Integration of vehicle detection and distance estimation using stereo vision for real-time AEB system. In Proceedings of the 3rd International Conference on Vehicle Technology and Intelligent Transport Systems (VEHITS 2017), Porto, Portugal.
- Lim, Y. C., Lee, C. H., Kwon, S. ve Jung, W. Y., 2008. Distance estimation algorithm for both long and short ranges based on stereo vision system. Intelligent Vehicle Symposium, Eindhoven, The Netherlands.
- Lin, C. ve Lee, C., 1996. *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*. Prentice Hall, 813 p, USA.
- Liu, L. C., Fang, C. Y. ve Chen, S. W., 2017. A novel distance estimation method leading a forward collision avoidance assist system for vehicles on highways. *IEEE Transactions on Intelligent Transportation Systems*, 18(4), 937-949.
- Liu, Z. ve Chen T., 2009. The vehicle distance measurement system based on binocular stereo vision. First IITA International Joint Conference on Artificial Intelligence, Hainan Island, China.
- Masters, T., 1993. *Practical Neural Network Recipes in C++*. Academic Press, 493 p, New York.
- Mrovlje, J. ve Vrancic, D., 2008. Distance measuring based on stereoscopic pictures. Paper presented at the 9th International PhD Workshop on Systems and Control: Young Generation Viewpoint, Izola, Slovenia.
- Nedevschi, S., Danescu, R., Frentiu, D., Marita, T., Oniga, F., Pocol, C., Schmidt, R. ve Graf, T., 2004. High accuracy stereo vision system for far distance obstacle detection. 2004 IEEE Intelligent Vehicles Symposium, Parma, Italy.
- Neves, A. C., González, I., Leander, J. ve Karoumi, R., 2018. A New Approach to Damage Detection in Bridges Using Machine Learning. *Experimental Vibration Analysis for Civil Structures*, Conte J., Astroza R., Benzoni G., Feltrin G., Loh K., Moaveni B. (eds). Springer, Cham, 73-84.
- Olaverri-Monreal, C., Krizek, G. C., Michaeler, F., Lorenz, R. ve Pichler, M., 2018. Collaborative approach for a safe driving distance using stereoscopic image processing. *Future Generation Computer Systems*, 95(2019), 880-889.
- Otsu, N., 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9 (1), 62-66.
- Öztemel, E., 2003. *Yapay Sinir Ağları*. Papatya Yayıncılık, 232 s, İstanbul.
- Park, K. Y. ve Hwang, S. Y., 2014. Robust range estimation with a monocular camera for vision-based forward collision warning system. *The Scientific World Journal*, Article ID 923632, 9 Pages.
- Pollefeys, D., Nistér, D., Frahm, J. M., Akbarzadeh, A., Mordohai, P., Clipp, B., Engels, C., Gallup, D., Sinha, S., Talton, B., Wang, L., Yang, Q., Stewénius H., Yang, R., Welch, G. ve Towles, H., 2008. Detailed real-time urban 3d reconstruction from video. *International Journal of Computer Vision*, 78(2-3), 143-167.
- Rafique, M.A., Pedrycz, W. ve Jeon M., 2017. Vehicle license plate detection using region-based convolutional neural networks. *Soft Comput* 22, 6429-6440.
- Safaei, A., Tang, H.L. ve Sanei, S., 2016. Real-time search-free multiple license plate recognition via likelihood estimation of saliency. *Computers and Electrical Engineering*, 56(2016), 15-29.

- Salman, Y. D., Ku-Mahamud, K. R. ve Kamioka, E., 2017. Distance measurement for self-driving cars using stereo camera. Proceedings of the 6th International Conference of Computing & Informatics, Kuala Lumpur, Malaysia.
- Seo, D., Park, H., Jo, K., Eom, K., Yang, S. ve Kim, T., 2013. Omnidirectional Stereo Vision Based Vehicle Detection and Distance Measurement for Driver Assistance System. IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society, Vienna, Austria.
- Sheela, K. G. ve Deepa, S. N., 2013. Review on Methods to Fix Number of Hidden Neurons in Neural Networks. Mathematical Problems in Engineering, Article ID 425740(2013).
- Shibata, K. ve Ikeda, Y., 2009. Effect of number of hidden neurons on learning in large-scaled layered neural networks. ICROS-SICE International Joint Conference 2009, Fukuoka, Japan.
- Simpson, P.K., 1990. Artificial Neural Systems: Foundations, Paradigms, Applications, and Implementations. Pergamon Press, 209 p, USA.
- Soytürk, M. A., 2005. Sayısal Kenar Çıkarma ve Yapay Sinir Ağları Yardımıyla Araç Tanıma. (Y.Lisans Tezi), Erciyes Üniversitesi Fen Bilimleri Enstitüsü / Elektronik Mühendisliği Ana Bilim Dalı, Kayseri.
- Sönmez Çakır, F., 2019. Yapay Sinir Ağları. Nobel Akademik Eğitim Danışmanlık Tic. Ltd. Şti., 108 s, Ankara.
- Şahin, M., 2019. Sivas İlinin Güneş Işınım Şiddeti ve Rüzgâr Hızının Yapay Sinir Ağları ile Tahmin Edilmesi. (Y.Lisans Tezi), Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü / Makine Mühendisliği Ana Bilim Dalı, Sivas.
- Şen, Z., 2004. Yapay Sinir Ağları İlkeleri. Su Vakfı Yayınları, 183 s, İstanbul.
- Şenel, H. G., 2007. Kenar bulma için topolojik gradyan işleçleri. Eskişehir Osmangazi Üniversitesi Müh. Mim. Fak. Dergisi, 20(2), 135-158.
- Tamura, S. ve Tateishi, M., 1997. Capability of a four-layered feedforward neural network: Four layers versus three. IEEE Transaction on Neural Networks, 8(2), 251-255.
- Tang, Z. ve Fishwick, P. A., 1993. Feedforward neural nets as models for time series forecasting. ORSA Journal on Computing, 5(4), 374-385.
- Toulminet, G., Bertozzi, M., Mousset, S., Bensch, A. ve Broggi, A., 2006. Vehicle detection by means of stereo vision-based obstacles features extraction and monocular pattern analysis. IEEE Transactions on Image Processing, 15(8), 2364-2375.
- Tram, V. T. B. ve Yoo, M., 2018. Vehicle-to-vehicle distance estimation using a low-resolution camera based on visible light communications. IEEE Access, Vol. 6, 4521-4527.
- Vogl, T. P., Mangis, J. K., Rigler, A. K., Zink, W. T. ve Alkon, D. L., 1988. Accelerating the convergence of the backpropagation method. Biological Cybernetics, 59, 257-263.
- Wong, F. S., 1991. Time series forecasting using backpropagation neural networks. Neurocomputing, 2(4), 147-159.
- Wu, C. F., Lin, C. J., Lin, H. Y. ve Chung, H., 2013. Adjacent lane detection and lateral Vehicle Distance Measurement Using Vision-Based Neuro-Fuzzy Approaches. Journal of Applied Research and Technology, 11(2), 251-258.

- Yavuz, G., 2008. Plaka Tanıma Sistemi. (Y. Lisans Tezi), Sakarya Üniversitesi Fen Bilimleri Enstitüsü / Bilgisayar ve Bilişim Mühendisliği Ana Bilim Dalı, Sakarya.
- Yazıcı, A. C., Ögüş, E., Ankaralı, S., Canan, S., Ankaralı, H. ve Akkuş, Z., 2007. Yapay sinir ağlarına genel bakış. Türkiye Klinikleri J Med Sci, 27(1), 65-71.
- Yıldız, A. K., 2016. Büyükbaş Hayvanlarda Kızgınlığın (Östrus) Hareketlilik ve Çevre Verilerinden Yararlanarak Yapay Sinir Ağları ile Belirlenmesi. (Doktora Tezi), Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü / Biyosistem Mühendisliği Ana Bilim Dalı, Tokat.
- Yıldız, B., 2009. Finansal Analizde Yapay Zeka. Detay Yayıncılık, 296 s, Ankara.
- Yuan, Y., Zou, W., Zhao, Y., Wang, X., Hu, X. ve Komodakis, N., 2017. A robust and efficient approach to license plate detection. IEEE Transactions on Image Processing, 26(3), 1102-1114.
- Yoo, I. ve Seo, S., 2017. Accurate object distance estimation based on frequency-domain analysis with a stereo camera. IET Intelligent Transport Systems, 11(4), 248-254.
- Zaarane, A., Slimani, I., Hamdoun, A. ve Atouf, I., 2019. Vehicle to vehicle distance measurement for self-driving systems. 6th International Conference on Control, Decision and Information Technologies (CoDIT'19), Paris, France.
- Zang, G., Patuwo, B. E. ve Hu, M. Y., 1998. Forecasting with artificial neural networks: The state of art. International Journal of Forecasting, 14(1), 35-62.
- Zhang, Z., Ma, X. ve Yang, Y., 2003. Bounds on the number of hidden neurons in three-layer binary neural networks. Neural Networks, 16(7), 995-1002.

## 7. ÖZGEÇMİŞ

### Kişisel Bilgiler

Adı Soyadı: Özgür DURAN

Doğum Yeri: Havza/SAMSUN

Doğum Yılı: 1982

### Eğitim

Derece	Eğitim Birimi	Mezuniyet Yılı
Lisans	Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği	2017
Lisans	Zonguldak Karaelmas Üniversitesi Karabük Teknik Eğitim Fakültesi Elektronik ve Bilgisayar Eğitimi	2005
Lise	Tokat Anadolu Lisesi	2000