



**BİLECİK ŞEYH EDEBALI
ÜNİVERSİTESİ**

**Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği**

**DERİN ÖĞRENME YÖNTEMİ İLE KÖPEK
DAVRANIŞLARININ ANALİZİ VE SINIFLANDIRILMASI**

**Rukiye POLATTİMUR
Yüksek Lisans**

**Tez Danışmanı
Dr. Öğr. Üyesi Emre DANDIL**

**BİLECİK, 2019
Ref.No:10225456**



**BİLECİK ŞEYH EDEBALI
ÜNİVERSİTESİ**

**Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği**

**DERİN ÖĞRENME YÖNTEMİ İLE KÖPEK
DAVRANIŞLARININ ANALİZİ VE SINIFLANDIRILMASI**

**Rukiye POLATTİMUR
Yüksek Lisans**

**Tez Danışmanı
Dr. Öğr. Üyesi Emre DANDIL**

BİLECİK, 2019



**BİLECİK SEYH EDEBALI
UNIVERSITY**

**Graduate School of Sciences
Department of Computer Engineering**

**ANALYSIS AND CLASSIFICATION OF DOG
BEHAVIOURS USING DEEP LEARNING**

**Rukiye POLATTİMUR
Master's Thesis**

**Thesis Advisor
Asst. Prof. Emre DANDIL**

BİLECİK, 2019



BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS
JÜRİ ONAY FORMU

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun 20/12/2018 tarih ve 74-1 sayılı kararıyla oluşturulan jüri tarafından 04/01/2019 tarihinde tez savunma sınavı yapılan Rukiye POLATTİMUR'un "*Derin Öğrenme Yöntemi ile Köpek Davranışlarının Analizi ve Sınıflandırılması*" başlıklı tez çalışması Bilgisayar Mühendisliği Ana Bilim Dalında YÜKSEK LİSANS tezi olarak oy birliği ile kabul edilmiştir.

JÜRİ

ÜYE
(TEZ DANIŞMANI) : Dr. Öğr. Üyesi Emre DANDIL

ÜYE : Dr. Öğr. Üyesi Süleyman UZUN

ÜYE : Dr. Öğr. Üyesi Kerim Kürşat ÇEVİK

ONAY

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun
...../...../..... tarih ve/..... sayılı kararı.

İMZA/ MÜHÜR

TEŐEKKÜR

Çalıřmalarımı yönlendiren, arařtırmalarımın her ařamasında bilgi, öneri ve yardımlarını esirgemeyen bařta danıřman hocam sayın Dr. Öğr. Üyesi Emre DANDIL olmak üzere, tez çalıřmama katkı sunan Öğr. Gör. Ali Osman SELVİ ve Öğr. Gör. M. Süleyman YILDIRIM hocalarıma ve köpeklerin video çekimlerinin yapılmasını saęlayan Öğr. Gör. İbrahim KILIÇ hocama teőekkür ederim. Ayrıca her zaman yanımda olan ve manevi desteklerini hiçbir zaman esirgemeyen aileme sonsuz teőekkürlerimi sunarım.

Ayrıca bu çalıřma Bilecik Őeyh Edebalı Üniversitesi BAP Koordinatörlüęü tarafından 2017-01.BŐEÜ.03-09 no.lu proje ile desteklenmiřtir. Bilecik Őeyh Edebalı Üniversitesi BAP Koordinatörlüęü'ne katkılarından dolayı teőekkürlerimi sunarım.

Rukiye POLATTİMUR

ÖZET

Hayvan yüzlerinin, vücut duruşlarının, davranışlarının ve fiziksel hareketlerinin gözlenmesi ve tanınması son zamanlarda disiplinlerarası bir alan olarak ön plana çıkmıştır. Bilgisayarlı görü, sayısal görüntü işleme gibi alanlardaki önemli teknolojik gelişmeler, videolar üzerinde insan davranışlarının analizinde kullanılabilmesinin yanında hayvan davranışlarının tespit edilmesinde yardımcı bir yöntem olmaktadır. Hayvanlarda, özellikle davranışların bilgisayarlı görü yöntemiyle tespiti ile ortaya çıkabilecek sonraki davranışların öngörülmesine ve hayvanların evcilleştirilmesine katkı sunabilir. Önerilen tez çalışmasında, köpeklerin davranışlarının analiz edilmesi ve sınıflandırılması için derin öğrenmeye dayalı bir sistem önerilmiştir. Giydirilebilir aksiyon kamera ve sabit kamera kullanılarak insanlar ile temastan kaçınmayan iki farklı türde köpeğin davranışlarını içeren videolar toplanarak bir veri seti oluşturulmuştur. Sonraki aşamada ise, köpeklerin davranışlarını analiz eden ve sınıflandırılmasını sağlayan derin öğrenme tabanlı uygulama gerçekleştirilmiştir. Elde edilen videolar üzerinde gerekli analizler yapıldıktan sonra belirlenen ağız açma, dil çıkarma, kulak dikme, kuyruk sallama, koklama, oyun oynama gibi davranışlar videolardan çıkarılarak, daha anlamlı bölümlerden oluşan özelleştirilmiş bir veri seti getirilmiştir. Bu videolardan anlamlı bölümlerin elde edilmesi ve özellik çıkarımı yapıldıktan sonra R-CNN (Bölgesel Evrişimsel Sinirsel Ağlar) ile belirlenen davranışların analizi gerçekleştirilmiştir. Yapılan deneysel çalışmalar üzerinde, köpeklerin ağız açma, dil çıkarma, kulak dikme, kuyruk sallama, koklama, oyun oynama davranışları incelenmiş ve bu davranışlar için sırasıyla %100, %99.99, %99.99, %95.99, %99.28, %99.64 eğitim başarımı elde edilmiştir.

Anahtar Kelimeler:

Derin Öğrenme; Evrişimsel Sinir Ağları (ESA, CNN); Bilgisayarlı Görü; Köpek Davranışları; Hayvan Davranış Tespiti.

ABSTRACT

Observation and recognition of animal faces, body postures, behaviors, and physical movements has recently become one of the most fundamental tasks of multidiscipline. The outstanding technological advances in areas such as computer vision and digital image processing can be used in the analysis of human behaviors on videos, as well as helping to detect animal behavior. In animals, it can contribute to the prediction of subsequent behaviors that may occur with computerized vision, and to domesticate animals. In the proposed thesis work, a system based on deep learning has been proposed to analyze and classify the behavior of dogs. A database was created by collecting videos showing the behavior of two different species dogs that do not avoid contact with people by using the wearable action camera and fixed camera. In the next stage, a deep learning-based application was conducted to analyze and classify the behavior of dogs. Determined behaviors such as mouth opening, tongue out, ears up, tail wagging, sniffing, playing, after the necessary examinations were made on the obtained videos, a special set of more meaningful sections was introduced. After feature extraction and obtaining meaningful sections from these videos, analysis of the behavior was performed by R-CNN. On the experimental studies, the behavior of the dog such as mouth opening, tongue out, sniffing, ears up, tail wagging, playing was examined and, training performance was obtained 100%, 99.99%, 99.28%, 99.99%, 95.99%, 99.64% for these behaviors, respectively.

Keywords:

Deep Learning; Convolutional Neural Networks (CNN); Computer Vision; Dog Behaviours; Animal Behavior Detection

İÇİNDEKİLER

Sayfa No

TEŞEKKÜR.....
ÖZET.....	i
ABSTRACT	ii
İÇİNDEKİLER.....	iii
SİMGELER VE KISALTMALAR	v
ÇİZELGELER DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
1. GİRİŞ.....	1
1.1. Literatür Taraması.....	3
2. KÖPEK DAVRANIŞLARI.....	8
2.1. Köpek-İnsan İlişkisine Bakış	9
2.2. Köpek Davranışı ve Psikolojisi.....	11
2.3. Köpek Beden Dili.....	11
2.4. Köpekleri Eğitme Yöntemi.....	12
2.5. Bazı Özel Yetenekli Köpekler ve Özellikleri	13
3. MATERYAL VE YÖNTEM.....	19
3.1. Çalışma Alanı ve Köpekler.....	20
3.2. Veri Toplama ve Video Veri Setinin Oluşturulması.....	20
3.3. Derin Öğrenme.....	25
3.3.1. Derin Öğrenme Ağı İşlem Adımları.....	27
3.3.1.1. Konvolüsyonel sinir ağları (CNN)	28
3.3.1.2. Konvolüsyon	31
3.3.1.3. Pooling (Havuzlama Katmanı).....	31
4. DERİN ÖĞRENME TABANLI KÖPEK DAVRANIŞLARININ ANALİZİ VE SINIFLANDIRILMASI	35
4.1. Derin Öğrenme Algoritması ile Sistemin Eğitilmesi	38
4.2. Elde Edilen Videolardan Anlamlı Bölümlerin Alınması.....	40
4.3. Anlamlı Bölümlerden Çerçeveler/Görüntüler Elde Edilmesi.....	40

4.4. CNN Algoritması ile Eğitim Kümesi Üzerinde İşlem Adımlarının Takip Edilmesi.....	44
4.5. Eğitilmiş Veri Seti Kullanılarak, Davranışların Analiz Edileceği Test Veri Setindeki Videolar Üzerinde Sistem Başarımlarının Test Edilmesi	50
4.6. Deneysel Çalışmalar.....	51
4.6.1. Ağız açma	52
4.6.2. Dil çıkarma.....	56
4.6.3. Koklama.....	60
4.6.4. Kulak dikme.....	63
4.6.5. Kuyruk sallama	66
4.6.6. Oyun oynama	69
5. TARTIŞMA VE SONUÇLAR.....	72
KAYNAKLAR.....	75
ÖZGEÇMİŞ.....	80

SİMGELER VE KISALTMALAR

Kısaltmalar:

CIFAR	:Canadian Institute For Advanced Research
CNN	:Convolutional Neural Network
ESA	:Evrışimsel Sinir Ağı
GND	:Ground
GPRS	:General Packet Radio Service
GPS	:Global Positioning System
GPU	:Central Processing Unit
GSM	:Global System For Mobile Communications
KNN	:K-Nearest Neighborhood
LBPH	:The Local Binary Pattern Histogram
LDA	:Linear Discriminant Analysis
LSTM	:Long Short Term Memory
MLP	:Multi-Layer Perceptron
PCA	:Principal Component Analysis
ReLu	:Düzleştirilmiş Doğrusal Birim Katmanı
R-CNN	:Regions With Convolutional Neural Networks
RPN	:Region Proposal Network
RX	:Receive X (Portu)
SGDM	:Stochastic Gradient Descent With Momentum
SMS	:Short Message Service
SVM	:Support Vector Machine
TBA	:Temel Bileşen Analizi
TX	:Transmit X (Portu)
YSA	:Yapay Sinir Ağları

ÇİZELGELER DİZİNİ

	Sayfa No
Çizelge 3.1. Köpeklerin altı farklı davranışı gösterdikleri eylemler için tanımlama (ASPCA, 2018).	23
Çizelge 3.2. Oluşturulan veri seti hakkında detaylar	244
Çizelge 4.1. CNN ağının eğitilmesi için kullanılan parametreler	39
Çizelge 4.2. Ağız açma hareketi sınıflandırma sonuçları	53
Çizelge 4.3. Dil çıkarma hareketi sınıflandırma sonuçları	56
Çizelge 4.4. Koklama hareketi sınıflandırma sonuçları	60
Çizelge 4.5. Kulak dikme hareketi sınıflandırma sonuçları	63
Çizelge 4.6. Kuyruk sallama hareketi sınıflandırma sonuçları	66
Çizelge 4.7. Oyun oynama hareketi sınıflandırma sonuçları	69

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 2.1. 161 farklı ırktan toplam 1346 köpekten elde ettikleri verileri kullanarak gerçekleştirdikleri köpek türleri ve onların atalarının soy ağacı (Elsevier Health Books and eBooks'dan, 2017).	9
Şekil 2.2. Köpek vücut dili (Doggie Drawings, 2018).....	12
Şekil 3.1. Önerilen tez çalışmasının işlem adımlarını ve yöntemlerini gösteren blok diyagram.	19
Şekil 3.2. Oyun oynama içeriğine sahip videolardan alınan davranış çerçeveleri. ...	21
Şekil 3.3. Köpeklerde analizi yapılacak olan tanımlanmış altı özel hareket.	22
Şekil 3.4. MATLAB'de CIFAR-10 resim kütüphanesi.	27
Şekil 3.5. Evrişimsel sinir ağı (CNN) yapısı.	29
Şekil 3.6. R-CNN modeli.	30
Şekil 3.7. Filtrenin iki kere kaydırılmasıyla oluşan öznitelikler.....	31
Şekil 3.8. Havuzlama işlemi.	32
Şekil 3.9. ReLU aktivasyon fonksiyonu.....	33
Şekil 4.1. Kullanılan CNN'nin mimarisi.	36
Şekil 4.2. Köpek davranış analizi işlemlerinin akış şeması.	38
Şekil 4.3. Özelleştirilmiş video içerikleri.	40
Şekil 4.4. Köpeğin ağız açma hareketleri sırasında alınan videolardan elde edilen çerçeveler.	41
Şekil 4.5. Köpeğin dil çıkarma hareketleri sırasında alınan videolardan elde edilen çerçeveler.	41
Şekil 4.6. Köpeğin koklama hareketleri sırasında alınan videolardan elde edilen çerçeveler.	42
Şekil 4.7. Köpeğin kulak dikme hareketleri sırasında alınan videolardan elde edilen çerçeveler.	42
Şekil 4.8. Köpeğin kuyruk sallama hareketleri sırasında alınan videolardan elde edilen çerçeveler.....	43
Şekil 4.9. Köpeğin oyun oynama hareketleri sırasında alınan videolardan elde edilen çerçeveler.	43

- Şekil 4.10.** Köpeğin altı farklı hareketi/davranışları için ilgili bölgenin işaretlenmesi. a) ağız açma bölgesi, b) dil çıkarma bölgesi, c) kuyruk sallama bölgesi, d) kulak dikme bölgesi, e) koklama bölgesi, f) oyun oynama bölgesi. 44
- Şekil 4.11.** Köpeğin altı farklı hareketi/davranışları için ROI bölgesinin bulunması. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi. 45
- Şekil 4.12.** Köpeğin sergilediği altı farklı hareketi/davranışları için ilgili alanın işaretlenmesi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi. 46
- Şekil 4.13.** Köpeğin altı farklı hareketlerinin/davranışlarının eğitim videoları boyunca yeşil işaretçiler (tracker) ile izlenmesi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi..... 47
- Şekil 4.14.** Pozisyonları çıkarılmış veri seti eğitime tabi tutulduktan sonra sistemin eğitilip eğitilmediğinin gösterildiği altı farklı hareketin/davranışın sarı çerçeve ile gösterimi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi..... 48
- Şekil 4.15.** Altı farklı hareket/davranışlar için, pozisyonları çıkarılmış veri seti eğitime tabi tutulduktan sonra eğitim başarı sonuçlarının gösterilmesi. a) ağız açma hareketi %100, b) dil çıkarma hareketi %99.99, c) kuyruk sallama hareketi, %99.99, d) kulak dikme hareketi %95.99, e) koklama hareketi %99.28, f) oyun oynama hareketi %99.64 başarı elde edilmiştir. 49
- Şekil 4.16.** Köpeğin altı farklı hareket/davranış için test veri setinde ilgili hareketlerin tracker ile izlenmesi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi..... 50
- Şekil 4.17.** Köpeğin ağız açma hareketi sınıflandırma sonuçları için örnek çerçeveler. 54
- Şekil 4.18.** Köpeğin ağız açma hareketi sınıflandırma sonuçları için örnek çerçeveler. 55

Şekil 4.19. Köpeğin dil çıkarma hareketi sınıflandırma sonuçları için örnek çerçeveler.	58
Şekil 4.20. Köpeğin dil çıkarma hareketi sınıflandırma sonuçları için örnek çerçeveler.	59
Şekil 4.21. Köpeğin koklama hareketi sınıflandırma sonuçları için örnek çerçeveler. ...	61
Şekil 4.22. Köpeğin koklama hareketi sınıflandırma sonuçları için örnek çerçeveler	62
Şekil 4.23. Köpeğin kulak dikme hareketi sınıflandırma sonuçları için örnek çerçeveler.	64
Şekil 4.24. Köpeğin kulak dikme hareketi sınıflandırma sonuçları için örnek çerçeveler.	65
Şekil 4.25. Köpeğin kuyruk sallama sınıflandırma sonuçları için örnek çerçeveler. ..	67
Şekil 4.26. Köpeğin kuyruk sallama sınıflandırma sonuçları için örnek çerçeveler. ..	68
Şekil 4.27. Köpeğin oyun oynama sınıflandırma sonuçları için örnek çerçeveler.	70
Şekil 4.28. Köpeğin oyun oynama sınıflandırma sonuçları için örnek çerçeveler.	71

1. GİRİŞ

Binlerce yıldır insanoğluna çeşitli alanlarda hizmet eden köpekler, sahip olduğu yetenekleri eğitimlerle daha da özelleştirerek insanlara faydalı olmaya devam etmektedirler. Köpekler artık günlük yaşantımızın bir parçası olmuşlardır. Bu birliktelik günlük hayatımızda, kızak köpekleri, mineral arama köpekleri, mantar bulma köpekleri, koruma köpekleri, polis köpekleri, bekçi köpekleri, duyma-görme engelli kişiler için özel eğitilmiş köpekler, enkaz arama köpeği gibi birçok özel alanda karşımıza çıkmaktadır. Hayatımızda bu kadar var olan köpeklerle ilgi olarak onların psikolojilerinin araştırıldığı, sahiplendirildiklerinde değişen davranış yapılarının incelendiği (Prato-Previd E., vd, 2018), gösterdikleri ruhsal veya davranış bozukluklarının tespit edilerek hangi eğitimlerin verilmesi gerektiği üzerine (Landsberg, G., M., vd., 2018) bir çok disiplinler arası çalışmalar yürütülmüştür. Bu çalışmalar ek olarak 105 köpeğin veteriner gözetiminde 170 farklı davranışsal problemin tespit edildiği bir çalışma yürütülmüş (Wright ve Nesselrote, 1987). Nitekim hayvanları daha iyi anlamak, onların sağlık sorunlarına hızlı çözümler bulmak (Aenishaenslin, C., vd., 2018), psikolojik olarak kendilerini daha güvende hissedecekleri ortamlar oluşturmak için bu tip çalışmaların geliştirilmesi, köpeklerden aldığımız hizmetlerin kalitesini arttıracak ve onlarla daha uyumlu yaşamamıza olanak verecektir. Ayrıca köpek havlamalarının sınıflandırılması çalışmaları (Lu ve Grauman, 2013) ile davranış analizi konusu iç içe geçirilerek günlük hayatta bizlere daha faydalı olacağı düşünülmektedir.

Köpeklerin askeri ve hizmet amaçlı eğitimi; fazla masraf, yoğun çaba, özel personel ihtiyacı ve uzun zaman periyotları gerektirmektedir (T. N. Y. Times, 2011). Önerilen tez çalışmasında, köpeklerin kameralarla izlenerek ve bilgisayarlı görü destekli makine öğrenmesi yöntemleri ile davranışlarının analiz edilerek zaman ve personel problemlerin azaltılmasına katkı sağlaması hedeflenmektedir. Ek olarak, engelli bir insanın günlük yaşantısında rehberlik eden bir köpeğin izlenmesi davranışlarının takip edilmesi, hayati sonuçlar doğurabilecek problemler için bu kişileri koruyacağı düşünülmektedir. Bu nedenle, tüm özel amaçlar için yetiştirilmiş köpeklerin veya herhangi bir sokak köpeğinin davranışlarının anlaşılması, takip edilmesi insanların günlük yaşam standartlarını arttırabileceği gibi köpeklerin de günlük yaşam kalitelerini arttıracığı düşünülmektedir. Ayrıca diğer özel eğitilmiş köpeklerin de günlük hayatımızda

daha çok var olmaları ve insan-köpek fayda alanlarının arttırılması için son teknolojiler ile bu birliktelik daha da geliştirilebileceği önerilmektedir.

Bugüne kadar köpeklerin ne tip davranış sergilediğini eğitmenler, veterinerler veya sahipleri anlamaya çalışırken, günümüzde video çerçeveleri üzerinden alınan görüntüler ile insan görüşüne çok yakın davranış analizi ve hareket tanıma artık yapılabilmektedir (Peterson, J., vd., 2018). Hatta eğitilecek köpeklerde görme, görme perspektifi, görme keskinliği, form algısı ve renk vizyonu gibi çeşitli görme araştırmaların yapılması, uzman köpeklerin görevlerdeki performansını nasıl etkileyebileceği ayrı bir merak konusu olmuştur (Byosiere, S., E., vd., 2018). Bu çalışmalara paralel olarak bilgisayar görüşü ve makine öğrenmesi alanlarındaki gelişmeler nesnelere tanınması konusunda bu tip güçlü sistemlerin geliştirilmesine olanaklar sağlamaktadır. Bu yaklaşımlar sayesinde, günlük hayatımızda hareketlerinde farklılık gözlenen köpekler için mevcut sorunlarına en iyi yaklaşımı getirerek çözüm bulmamızı sağlayacak ve onların eğitim süreçlerine yön verecektir. Bunlara ek olarak bu sistemler ile davranış örüntülerinin tanınması amacıyla yeni yaklaşımlar da önerilmektedir. Bu yaklaşımlar hem insan görme sistemini daha iyi anlama temeline dayanmakta hem de karma özellik çıkarım mekanizmaları ile en iyi başarı oranlarını elde etme hedeflenmektedir. Ayrıca son yıllarda nesne tanıma amaçlı derin öğrenme yöntemlerinden yararlanma düşüncesi kayda değer bir şekilde artış göstermektedir (Sağiroğlu ve Koç, 2017). Derin öğrenme sistem çalışmalarında önemli başarı oranları elde edilmesi ve bilgisayar donanım yapılarının (GPU) gelişmesiyle birlikte derin öğrenme temelli araştırma konuları çok ilgi çekmeye başlamıştır. Derin öğrenme uygulamaları, doğal dil işleme, görüntü/video işleme, biyomedikal sinyal/görüntü işleme, araç otonom sistemleri, multimedya yönetimi, akıllı şehirlerin kurulmasında, akıllı trafik planlaması gibi alanlarda geniş uygulamalarla kendine yer bulmaktadır.

Mevcut derin sinir ağları, bilgisayarlı görü işlemlerinde dikkate değer bir performansa ulaşmıştır. Fakat derin ağlar söz konusu olduğunda sistemin öğrenme doğasının ne olduğu ve neden bu kadar iyi işlediği, belirsizliğini korumaktadır. Bu belirsizlik henüz tam açıklanmamış olsa da derin sinir ağların sahip olduğu yüksek kararlılık ve farklı katman yapısı kombinasyonlarına sahip olması, sistemin eğitilmesi aşamasında farklı yaklaşımlar getirilmesine yardımcı olmaktadır. Her bir katman yapısı, sistemin eğitimi aşamasında neyi aktifleştirdiğini görselleştirmek için uygun bir

prosedür sunmaktadır. Sistem çalışma aşamalarında, gerektiğinde katman yapısını değiştirilebilir veya farklı başarılı iki model kombinasyonlarından yararlanılabilmektedir (EhsaniK., vd., 2018). Derin öğrenme yapıları içerisinde birçok sınıflandırma modeli kullanılmaktadır. Görüntü tanıma ile ilgili olarak yapılan çalışmalarda CNN (Convolutional Neural Network, Evrimsel Sinir Ağları), en güçlü sınıflandırma modeli olarak karşımıza çıkmaktadır (Karpathy, vd., 2014; Koppula ve Saxena, 2015; Kitani, vd., 2012; Lan, vd., 2014; Liu, 2018; Rodin C., vd., 2018). CNN, bilgisayarlı görü uygulamalarında kullanılmak üzere geliştirilmiş çok katmanlı yapay sinir ağlarının özel bir modelidir. Yapısında konvolüsyon, havuzlama ve tam bağlı gibi kendine özgü görevleri olan ayrı katmanları barındırır.

Önerilen bu tez çalışmasında insan davranışlarını analiz eden bilgisayarlı görü uygulamalarına benzer olarak hayvan davranışlarını analiz eden bütüncül bir derin öğrenme tabanlı bir makine öğrenme sistemi geliştirilmiştir. Çalışmada köpek davranışlarının otomatik analizi ve köpeğin gerçek zamanlı takibi gerçekleştirilmiştir. Tezin çıktılarına uygun olacak şekilde köpeklerin davranışları incelenmiş ve takibi sağlanmıştır. Tez çalışmasında koklama, oyun oynama, dil çıkarma, kulak dikme ve kuyruk sallama olmak üzere altı farklı hareket temel alınarak köpeklerin doğal ortamlarında videoları toplanmıştır. Bu videoların içerikleri hareket bazlı incelenerek daha da özel veri setleri hazırlanmıştır. Veri setinde her bir hareket için ortalama 5 saniyelik 10 farklı video parçası bulunmaktadır. Bu video parçaları üzerinde köpeklerin davranışlarının analizi ve harekete göre sınıflandırılması sağlanmıştır.

1.1. Literatür Taraması

Köpekler doğal ortamlarında yaşarken tıpkı insanlar gibi belli hareketleri içeren günlük aktiviteler yapmaktadırlar. Köpeklerin yaptıkları bazı hareketleri günlük hayatta insanlar tarafında anlaşılması oldukça zor ve masraf gerektiren işlemlerdir. İnsani duygular ve hızlı karar verme söz konusunda insanların bu hareketleri anlaması ve tanımlaması oldukça zor olmaktadır. Bu problemi ortadan kaldırmak için otomatik karar verebilen bilgisayar görü destekli makine öğrenimi yöntemlerinden yararlanılmaktadır. Bu sistemlerin sınıflandırma başarı oranları yaklaşık %70 civarında tespit edilmiştir (Ladha C., 2013). Hayvanların davranışlarının tanınmasında bilgisayarla görme uygulamaları, hayvanlarla doğrudan etkileşime girme ihtiyacı olmadan ilgili özelliklerinin ölçülmesini sağladığı için caziptir.

Bilgisayarlı görü konusunda literatür çalışmaları incelendiğinde daha çok insan davranışlarının analizi temelinde çalışmaların yoğun olduğu görülmektedir. Bu çalışmalarda kameralar ile alınan video görüntüleri, bilgisayar algoritmaları ile incelenerek davranış tanıma işlemleri gerçekleştirilmektedir.

Düşük fiyatlı ve yüksek kaliteli giyilebilir kameralar son yıllarda piyasada sıklıkla kullanılmaktadır ve birçok çalışmada tercih edilmektedir. Giyilebilir kameralar sayesinde elde edilen videolar üzerinde yapılan analizler ve çalışmalar bilgisayarlı görü çalışması yapan araştırmacılar için popüler bir alan olmuştur (Pirsiavash ve Ramanan, 2012; Fathi, vd., 2011; Hammerla, vd., 2016; Cho, vd., 2008).

(Iwashita, vd., 2014) çalışmalarında farklı köpeklerin video görüntüleri üzerinde on farklı davranışının (topla oynama, arabanın geçmesini bekleme, su içme, beslenme, kafasını sola doğru çevirme, başını sağa çevirme, sevgi gösterisinde bulunma, silkelene, koklamak ve yürümek) analizini gerçekleştirmişlerdir. Bu çalışmada tercih edilen on hareketten farklı olarak önerilen tez çalışmasında koklama hareketi dışında çalışılan diğer hareketler farklılık göstermektedir. Ayrıca bu tez çalışmasında tüm videolar ego-centric (kafa bölgesine giydirilmiş) kameralar ile veriler alınmıştır.

(Ladha, vd., 2013) giydirilebilir sürekli kayıt yapar üç eksenli ivmeölçer yardımıyla köpektan datalar toplanmış ve 18 köpeğin 17 hareketi (belirtilmemiş, yürüme, koşu, atlama, kazma, uzanma, oturma, havlama, çiğneme, yemek yeme, içme, esneme, koklama, sarsılma, idrar yapma, tuvalet yapma, silkelene) için PCA (TBA, Temel Bileşen Analizi) tabanlı özellik çıkarımı ve örnek tabanlı (instance-based learning) bir öğrenme sınıflandırması metodu kullanılmıştır. Bu tez çalışmasından farklı olarak önerilen tez çalışmasında sadece koklama hareketi benzerlik gösterirken aynı zamanda probleme çözüm bulma methodlarında farklılık göstermektedir.

(Leos-Barajas, vd., 2016) bir köpeğe giydirilmiş ivmeölçer ile hayvan davranışlarının analizi çalışmasını HMM (Hidden Markov Model) kullanarak gerçekleştirmiştir. Denetimli ve denetimsiz öğrenme methodlarını, köpek davranışlarının durum tahmini ve köpeklerin biyolojik olarak daha anlamlı hareketlerin sınıflandırılması için kullanmışlardır.

(Gerencser, vd., 2013), köpeğe giydirilmiş ivme ölçer ve kamera ile alınan dataların değerlendirildiği farklı bir çalışmada ise çalışmalarında takip edilecek hareketleri belirleyerek (durma, yürüme, koşma, vd), SVM (Support Vector Machine,

Destek Vektör Makineleri) öğrenme algoritması kullanarak sınıflandırma işlemi yapmışlardır.

(Brugarolas, vd., 2013) ise makine öğrenmesi yöntemlerinden karar ağaçları ve HMM kullanarak kablosuz makine arayüzü ile sensörlerden aldıkları titreşim dataları yardımıyla köpeklerin davranışlarının tanınmasını önermişlerdir. Bu hareketleri statik ve dinamik olarak ikiye ayırmışlardır. Statik hareketler için; oturmak, ayakta durmak, uzanmak, iki ayak üzerinde durmak ve yerden yemek yemek, dinamik hareketler için; yürümek, merdiven çıkmak ve bir rampadan aşağı inmek gibi hareketler tanımlamışlardır.

(Dodge and Karam, 2017) yine farklı tür köpeklerden elde edilmiş veri seti üzerinde yaptıkları çalışmada, çözünürlüğü iyi olan resimlerde makine ve insan neredeyse aynı başarı oranına sahipken bozuk görüntüler tanımada insanların daha başarılı olduğu göstermiştir. Ek olarak başarıyı artırmak için CNN bağlı bir model önerilmiştir.

(Ehsani K., vd., 2018), diğer bir çalışma da, CNN ve LSTM (Long Short Term Memory, Uzun Kısa Vadeli Hafıza Ağları) ile karma bir model oluşturarak köpeklerin kafa bölgesine giydirilen camera ile alınan görüntüleri alarak köpeğin mevcut duruma göre nasıl hareket edeceğinin öngörüsünü yapmışlardır.

(Labuguen R., vd., 2018) maymunlardan elde edilen veriler ile mevcut hareketlerinin tahmini ve bir sonraki hareketi öngörmeye çalışmışlardır. Maymunların özellikleri ve konumları üzerine yapılan bir çalışmada CNN öğrenme modelini kullanarak hayvanların doğal ortamlarındayken toplanan RGB resimleri kullanılmış ve özellik çıkarım işlemleri yapılmıştır.

(Ko K., vd., 2018) hayvan hareketlerinin yanı sıra bu çalışma da ise, 102 tür ve 3 sınıftan oluşan hayvan seslerini içeren bir veri oluşturulmuş, CNN ve SVM ile karma bir model oluşturarak bir çalışma geliştirmiştir. Ek olarak hayvan hareketlerinin tanınmasının yanı sıra, insan aktivitelerinin tanınmasında da CNN modeli kullanılmıştır.

(Ji S., vd., 2010) çalışmalarında, 3D konvolüsyonlar gerçekleştirerek, uzamsal ve zamansal boyutlardan özellikleri ayıklanmış veriler ile kodlanmış hareket bilgisini yakalamayı hedeflemiştir.

(Ryoo, vd., 2011), kamuya açık alanlarda insanların normal veya anormal davranışlarının doğru sınıflandırılması işlemini gerçekleştirmişlerdir. Bu yaklaşım ile

özellikle hasta, çocuk veya yaşlı insanların acil bir duruma ihtiyaçlarının olduğu durumlarda kullanışlı olmayı hedeflemişlerdir.

(Trnovszky, T., vd., 2017) çalışmasında sınıflandırma için CNN yapısını diğer iyi bilinen resim tanıma sınıflandırma yapıları olan PCA, LDA, LBPH ve SVM ile kıyaslamışlardır. Elde edilen sonuçlara göre en yüksek başarıya sahip sınıflandırma sisteminin CNN olduğunu görmüşür.

(Fathi, vd., 2011), nesnelere, eller ve eylemlerin görünüş ve tutarlılıklarına göre sadece yeme aktivitesini analiz etmişlerdir.

(Kitani, vd., 2011), önerilen tez çalışmasında olduğu gibi veri toplamak için bir aktivite kamerası kullanılmıştır ve elde edilen videolar üzerinde hareket tabanlı histogramlar kullanarak spor aktivitelerini incelemişlerdir.

Makineyle öğrenmesi yıllardır kullanılan bir yöntem olmasına rağmen, büyük data (big data) ve derin öğrenme (deep learning) yöntemleri GPU'ların özelliklerinin iyileştirilmesi ile birlikte çok daha fazla çalışma alanı bulmuştur ve bu çalışmalarda daha yüksek başarılar elde edilmeye başlanmıştır. Bu durum, farklı derin öğrenme modelleri tasarlanmasına da olanak sağlamıştır. Bu modellerden en yaygın kullanılan ve bu çalışmada kullanılan model CNN metodudur. Bu metodu kullanarak birçok çalışma gerçekleştirilmiştir (Ehsani K. vd., 2018; Karpathy, A. vd., 2014; Koppula H., vd., 2013; Kitani K, vd., 2012; Lan T., vd., 2014; Liu, Y., vd., 2018; Rodin, C., vd., 2018; Trnovszky, T., vd., 2017).

Tüm bu çalışmalardan yola çıkarak hareketlerin öngörülmesi, tahmin edilmesi çalışmaları farklı makine öğrenmesi teknikleri kullanılarak yapılabileceği görülmektedir (Kitani K., vd., 2012; Lan, T., vd., 2014; Ladha, C., vd., 2013). Bu çalışmalar bizlere günlük hayatta karşımıza çıkabilecek insanlardan, nesnelere veya hayvanlardan kaynaklı problemlere karşı çözüm bulunabileceği göstermektedir.

Önerilen bu tez çalışmasının diğer tüm çalışmalardan farkı, farklı köpeklerin doğal ortamlarında sergiledikleri altı farklı hareket (ağız açma, dil çıkarma, koklama, kulak dikme, kuyruk sallama, oyun oynama) için yapılmış olmasıdır. Literatür taraması yapıldığında, bu altı hareket içerisinde sadece koklama hareketi çalışıldığı görülmektedir. Diğer beş hareket yapılan çalışmalarda tespit edilememiştir. Seçilen 6 farklı hareketin, köpeklerden elde edilen videolar izlendiğinde en çok sergilenen hareketler olduğu görülmüştür. Ayrıca diğer çalışmalar incelendiğinde bir çok

alıřmada kpeklerin izlenmesi tercih edilen ara ve gereler farklılık gstermektedir. Tm veri seti ise nerilen tez alıřması iin zel olarak hazırlanmıřtır. Elde edilen bu verilen daha sonra akademik olarak kullanılması iin paylařıma sunulmasını dřnlmektedir.

2. KÖPEK DAVRANIŞLARI

Kendilerine has genetik profillere ve fenotipik karakterlere sahip olan yaklaşık 400 köpek cinsi olduğu bilinmektedir. Bunların arasında 80 kilonun üzerine çıkabilen devasa danualardan 1 kilogram civarında olan fino köpeklerine kadar çok çeşitli nesiller bulunmaktadır. Biyolojik olarak köpeklerin gerçekte tek bir tür olduğu bilinmektedir. Buna karşın köpeklerin en yakın yaşayan akrabaları kurtlardır (Adams, 2008). Aslında ataları olduğu savunulan kurtlardan geldiği birçok özelliği hâlâ bazı köpekler taşımaktadırlar. Bunlardan bazıları: alan savunması, koruma, avlanma ve insandan güçlü koku duyuları gibi özellikleridir. Zaten köpeklerin ataları olan kurtların evcilleştirilmeleri de avlanma ve bekçilik gibi sebeplere dayanır. Bu iki türün genomlarının analiz edildiğinde bazı bilim adamlarının da savunduğu gibi insan etkisiyle yapay seleksiyonlara maruz kalmanın bir sonucu olduğu ortaya çıkmaktadır. 14.000 yıl öncesine dayanan evcilleştirme süreciyle birlikte doğuştan gelen veya atalarından gelmesi beklenen genomlar ile kıyaslandığında köpek genomundaki değişkenlikte bir artış olduğu anlaşılmaktadır (Björnerfeldt S., vd., 2006). Bu biyolojik anlamda değişiklik, köpek ırkları veya nesilleri 350 ile 400 arası bir sayıya ulaşmasına sebep olmuştur. Bu ırkların büyük bir çoğunluğu son 200 yıl içerisinde ortaya çıkmıştır. Genetik bilimindeki gelişmeler sayesinde bu ırkların genetik temellerini nerede ve nasıl karıştıklarını veya nasıl üretildiklerini kolaylıkla anlayabilmektedir.

Yaklaşık 50.000 yıl öncesinden başlayarak çoğunlukla da 30.000 ile 15.000 yıl önce evcilleştirilen ve yapay seleksiyon ile son derece hızlı şekilde evrilen ve değişen köpek türleri bugün hemen hemen birçok farklı alanlarda faydalandığımız son derece zeki bir tür olarak karşımıza çıkmaktadır (Pennisi, E., 2017). İnsanların etkisi ile yapay olarak da evrilen bu tür, evimizin ve hayvanlarımızın koruyucuları, şahsi korumalarımız, arama kurtarma ekiplerinin aranan elemanları, narkotik ve diğer suç araştırmalarının yardımcıları, görme engelliler için yol gösterici ve en önemlisi arkadaşlarımız olagelmıştır.

Elaine Ostrander, Heidi Parker ve National Human Genome Research Institute'tan genetikçiler, 20 yıldan fazla süredir köpek şovlarına ve yarışmalarına giderek köpeklerin davranışlarını gözlemlemeye, dünyanın farklı yerlerinden köpek DNA'sı örnekleri toplamaya ve deneyler yapmaya başlamışlardı. Hâli hazırda topladıkları verileri kullanarak gerçekleştirdikleri analiz ile 161 farklı ırktan toplam

özelliğidir. Bu özellik geçmişten bu yana iç içe yaşamının getirdiği bir özelliktir. Öyle ki en yakın hayvan akrabalarımız şempanzeler bile bu beceriye sahip değiller. Tam olarak bu birlikteliğin ne zaman başladığına dair somut kanıtlara ulaşmak için birçok arkeolojik kazı çalışmaları ortaya konulmuştur. Köpeklerin ilk evcilleştirilmesinin, tarım devrimi öncesine dayanan Mezolitik Dönemde meydana geldiğine dair genel bir kanı söz konusudur. Hatta birçok araştırmacı bu konuda hiç şüphe olmadığını ileri sürmektedir. Aslında beklentiler genelde köpeklerin atasının kurt olduğu düşünüldüğünde köpekleri ilk evcilleştiren topluluğun Türkler olduğu varsayımı yapılabilir ama bu tam olarak doğru değildir. Köpeklere ait en eski kalıntılar Kuzey Amerika'da bulunmuştur. Radyokarbon tekniği ile analiz edilen kalıntıların bulgularına göre, MÖ 7538 ± 350'e dayanmakta olduğu belirlenmiştir. Diğer bir bulguya göre ise, Almanya Senckenberg bataklığında bulunan köpek kalıntıları incelendiğinde daha ilkel bir tip olup daha kurt özellikleri gösterdiği açıklanmıştır. Anadolu'da ilk bulgular Çayönü'e MÖ 7000 yılına uzanmaktadır. Bununla birlikte Anadolu'da Değirmentepe'de kutsal anlamda ilk köpek iskeleti kalıntıları bu bölge de ortaya çıkarılmıştır. İnsanların köpeklerle yaşadıkları evlerini de paylaştıklarına dair güzel bir örneğe ise, Yakın Doğu'da (İsrail'de Yukarı Ürdün Vadisi'ndeki Huleh Gölü yakınında Ein Mallah yerleşiminde) rastlanılmıştır. Bir insan ile yaklaşık 4-5 aylık evrilmiş kurt ya da köpek yavrusu beraber gömülmüş olarak bulunmuştur. Arkeologlar bu buluntunun, insan-köpek ilişkisinin ne kadar derin olduğunu göstermesi açısından en önemli işaret olarak değerlendirilmişlerdir.

Evcilleştirilmenin kanıtı olarak tarihsel süreçleri göz önüne alındığında bazı morfolojik değişimler söz konusu olmuştur. Diş kemerlerinin kısılması ve dişlerin ebatlarının azalması, alt dişlerin pozisyonu ve sıkışıklığı, kafatasının yüz kısmının kısılması gibi bazı morfolojik değişimler, evcilleştirilme sürecinin başlamasında evcil - yabani form ayrımında temel alınan noktalar olmuştur. Bu değişim son dönemlere değil aslında oldukça erken zamanlarda Neolitik Dönemde uzanmaktadır. Ayrıca evcil köpeklerin beyin boyutlarında %20-30 oranında belirgin bir azalma olduğu belirlenmiştir. Bu azalma, özellikle beyincikte çok güçlü olmakla birlikte, burada var olan görme, koku, işitme merkezlerini oluşturan alanlardaki hacimlerin bir kısmını bu süreçte kaybetmiş oldukları bulunmuştur. Bu fonksiyonların evcil köpeklerde vahşi ataların olduğu boyutlarda olmaması evcilleştirme sürecinin köpeklerin üzerindeki

olumsuz yansıması olarak görülmektedir. Ek olarak genelde kısa bacaklı ve geniş burunlu küçük köpekler kategorisinde bulunan ilk evcil köpeklerin morfolojisi de bu süreç ile değişmeye başlamıştır (Aktuel Arkeoloji, 2018).

2.2. Köpek Davranışı ve Psikolojisi

Günümüzde insanların köpeklerle ilgili günlük yaşantısında bazı problemler yaşaması; onların alan koruması, avcılık ve gelişmiş koku alma duyuları gibi özelliklerinden kaynaklanıyor olmasıyla mümkündür. Aslında insanda olan alan koruması özelliği bazı durumlarda köpeklerde de güdüsel olarak görülebilmektedir. Örnek olarak bu hareketler sahiplerine karşı yapılan saldırılarda, sahiplerinin eşyalarının alınması durumunda, kendi yuvasının bulunduğu alanlara yapılan saldırılarda ortaya çıkmaktadır. Sonuçta bu tutum karşısında insanlarda korku ve panik oluşabilmektedir (Hillspet, 2018).

2.3. Köpek Beden Dili

Köpekler vücutları söz konusu olduğunda son derece etkileyici varlıklardır. Buradaki vücut tanımı; yüzleri, kulakları, kuyrukları ve genel duruşu içermektedir. Örneğin, eğer bir köpek kuyruğunu gizliyorsa, burnu buruşmuşsa, kulaklar arkada ve dudaklar hafifçe bükülmüşse bu onun endişe duyduğunun kesin bir işaretidir. Ama kuyruğu aşağı inmiş ve kulakları dik şekilde sakınse, kafa yukarıda, ağzı açık (biraz dil gösterecek şekilde) ve duruş sakınse, çok rahat olduğu ve oyun oynamak istediği anlamını taşır. Köpeğiniz çoğunu vücut duruşuyla ifade ettiği birçok ruh hali yaşıyor ve bunların hepsi çok önemli mesajlar içeriyor olabilir. Şekil 2.2' de vücut duruşları ve yüz ifadelerinden yola çıkarak ne hissettikleri belirtilmiştir (Hillspet, 2018).

KÖPEK VÜCUT DİLİ



Şekil 2.2. Köpek vücut dili (Doggie Drawings, 2018).

2.4. Köpekleri Eğitme Yöntemi

Köpeklerin çoğu kolayca eğitilebilir. Eğitime başlamadan önce onun bilmesini istediğiniz temel komutların bir listesini yapılmalıdır: "otur", "dur", "gel", "aşağı" veya "hayır". Ayrıca onun havlamasını kontrol etmek, masadan yemek istemesini sağlamak ve ev kazalarından kaçınmayı öğretmek; ev ortamını paylaşan her iki canlı için de daha güvenli bir yaşam alanına dönüştürülmüş olacaktır. Bunların hepsi son derece uygulanabilir komutlar olmakla birlikte, bu konuda tek gereken şey tutarlılık, övgü, ara sıra verilen ödül mamaları ve bol miktarda sabır ve pozitif yaklaşımlardan oluşmaktadır. Köpek eğitimine başladığımızda kazalar için hazırlıklı olmak, sabırlı ve pozitif yaklaşımdan uzaklaşmamak eğitimin başarılı geçmesi için sergilenmesi gereken önemli

tutumlarıdır. Bu, köpeğin eğitiminde en önemli kurallardan birisidir. Köpekler alışkanlıklarına bağlı varlıklardır. Bu yüzden mama yedikten, oynadıktan, şekerleme yaptıktan sonrası, eve kapatılmadan öncesi ve her çişini yapacak bir yer arayışına girmesini bir programa koymak önemli olacaktır. Doğru şekilde yaptığı her davranış için köpeğinize bol bol övgüde bulunulması gerekmektedir. Hatta sonrasında verilecek bir ödül maması onu bir sonraki sefere daha iyi motive etmesini sağlayacaktır. Zamanla köpeğiniz nereye ve ne zaman gideceğini öğrenmiş olacaktır. Başlangıçta hiç bir köpek mükemmel değildir, bir veya iki kez köpeğinizin dağınkılığını sizin temizlemeniz de ayrıca gerekebilir.

2.5. Bazı Özel Yetenekli Köpekler ve Özellikleri

Köpekler insanlarla geçmişten bugüne kadar çok yakın ilişkiler geliştirmişlerdir. Bu nedenle insanı algılama yetenekleri çok fazladır ve insanların en iyi dostudur. Dostluklarının yanında insanlar onları pek çok amaç için kullanmaktadır. Örneğin köpekler de insanlar gibi beş duyuya sahiptir. Bunlardan en gelişmiş koku alma duyusudur. İnsanlar yaklaşık 4 milyon kokuya duyarlı reseptöre sahipken, köpekler yaklaşık 220 milyon reseptöre sahiptir. Üzerinden 4 gün geçmiş olsada köpekler birinin izini 160 km ya kadar sürebilirler (Atuder, 2018). Bu yetileri sayesinde kayıp insanları bulabilirler. Bu özelliklerinin yanı sıra, hem gündüz hem gece boyunca fonksiyonel bir görüşe (Duke-Elder, 1958; Walls, 1942: Byosiere'dan (2018)), insanlara göre daha göze çarpan bir görme yetisine sahiptirler. Yani loş ışıkta gözleridaha iyi işlev görecektir. Köpeğin retinası büyük ölçüde çubuk fotoreseptör hücrelerden oluşur. Bu da daha az yoğun ışıklı çevrede çalışabilmelerini sağlamaktadır (Kemp ve Jacobson, 1992: Byosiere'dan (2018)). Köpeklerdeki retinal hücrelerin sadece %3'ü renk görüşünden sorumlu olan koni fotoreseptör hücreleridir (Peichl, 1992: Byosiere'dan (2018)). Bu oran insanlarda kabaca %5'e karşılık gelmektedir (Purves, Augustine, & Fitzpatrick, 2001: Byosiere'dan (2018)). Bu ve bunun gibi köpeklerin birçok farklı özelliklerini araştırarak günlük hayatımızda daha çok var olmalarını sağlanmalıdır. Köpekler birçok özel alanda eğitilerek insanlığa faydalı olmaktadır. Bunlardan bazıları aşağıdaki kısımlarda açıklanmıştır.

Arama ve Kurtarma Köpekleri

Köpekler evcilleştirilmelerinden beri, avcılıktan, korumaya ve sürü gütmeye tüm çalışma alanlarında insanlara yardım etmektedirler. Arama kurtarma için köpeklerin kullanılabilecekleri fikri ilk kez, 2. dünya savaşında Almanlar tarafından hava bombardımanına maruz kalan Londra şehrinde keşfedilmiştir. Evcil köpekler enkazlarda sahiplerini aramışlardır ve sahiplerini bulduklarında havlamaya başladıkları gözlemlenmiştir. Böylelikle köpekler afetlerde ve olağan üstü durumlarda kullanılmak üzere de hayatımıza girmişlerdir (Atuder, 2018). Örneğin, çığ arama kurtarma, köpek ihtiyacının acil olduğu nadir ilk yardım disiplinlerinden biridir. Olağanüstü koku duyusu, hızı ve kararlılığı onu ön plana çıkarır. Bununla birlikte köpek, delici ve kazıcıların da bulunduğu bir grubun üyesidir. Takımlar aynı anda çalışır fakat köpeklerin çığ üzerinde önceliği vardır. Köpeklerin önden sürülmesinin en önemli nedeni, köpekler çığ alanını daha hızlı keşfettiği için ilk yardım görevlileri çığa gömülen bireyler için olarak kurtarma olasılığını arttırmaktadır. Bu durumda, köpeğin rolü çok önemli bir hale gelir. Çalışması kalite açısından eşit veya yüksektir ve ayrıca köpek zemini daha hızlı bir şekilde keşfeder. Yirmi devriye polisi tarafından gerçekleştirilen tam bir araştırmada %100 sonuca ulaşmak için yirmi saat gerekirken aynı %100 sonuç için köpek bir hektarlık arsa üzerinde iki saat çalışır (Royal Canin, 2018).

Alman, Avusturyalı ve İsviçreli yardım organizasyonları tarafından 1991 tarihinde UN-INSARAG (Uluslararası Arama-Kurtarma Gurubu) kuruldu. USAR (Meskun Mahal Arama –Kurtarma) birliklerinin standartlaştırıldı ve 57/150 yasa ile bütün ülkelerdeki standartlar birliği sağlandı. INSARAG’a paralel olarak IRO (uluslararası Arama Kurtarma köpekleri organizasyonu) Kuruldu. IRO ile arama kurtarma köpeklerinin eğitim ve sınavlarının standartlaşması sağlandı. 40 ülkeden 118 kuruluş IRO üyesidir. Türkiye’de ise bu görevi AFAD üstlenmiştir (Atuder, 2018).

Kılavuz Köpekler

Kılavuz olarak kullanılan köpekler de itaat özellikleri ve öğrenme yetenekleri nedeniyle seçilirler. Eğitim birkaç aydan fazla sürer ve köpeğin asıl olarak itaati öğrendiği çeşitli dönemlere bölünür. Bu dönemler, köpeğin belli bir pozisyonda durmak zorunda olduğu, nesnelere bulup getirmeyi öğrendiği, koşumlarını giymeye alıştığı ve arka ayakları üzerinde düzgün şekilde yürümeyi öğrendiği basit egzersizlerden oluşur.

Bu aşama tamamen bir eğitici tarafından gerçekleştirilir. Bir sonraki aşamada köpek her türlü engelden kaçınmayı ve sahibini bu engellere karşı uyarmayı öğrenir. Bu, tüm eğitim döneminin en zorlu anıdır. Köpek daha sonra onun varlığına alışacak ve kendisini birçok durumda köpeğinin kılavuzluğuna bırakabilecek görme engelli bir kişiye teslim edilir. Bu kişi ve köpeği arasında daha sonra çok yakın bir ilişki oluşmaya başlar. Eğitimci ikisinin arasında bir bağlantı olarak hizmet eder ve ayrıca görme engelli kişi için de bir aracı olarak hareket eder. Kılavuz köpek okulunda geçen birkaç aydan sonra görme engelli kişi/köpek ikilisi günlük hayatı ve geçirecekleri az çok birkaç yılı karşılamaya hazırdırlar (Royal Canin, 2018).

Duym- görme engelli kişiler için köpekler

Dünyada, özellikle Amerika, İngiltere ve Hollanda'da bu gibi köpekleri eğiten birçok merkez bulunmaktadır. Bu köpekler genel olarak Golden Retriever ırkındandır ancak Welsh Gorgi ve Bearded Collie ırkları da kullanılmaktadır. Sekiz haftalıktan bir yaşına gelene kadar eğitim alacakları ve çok çeşitli yerlere (şehir, süper market, orman) alışacakları, ev sahibi ailelerin yanına (mümkünse çocuklu olan) yerleştirilirler. Köpek daha sonra gelecekteki işlevini etkin bir şekilde öğrenmek için eğitim merkezine geri döner. Irk seçimi burada çok önemlidir ve köpeğin öğrenme yetenekleri teste tabi tutulur. 70'ten fazla sözel komutu ve 20 beden hareketini öğrenmeleri gereklidir. Ayrıca sağır veya duyma bozukluğu olan bir kişinin ton ve diksiyonu oldukça farklıdır, bu nedenle sese adaptasyon için ek bir çaba gerekir. Sağır-dilsizler için yardım köpeklerinin eğitimi bir yerine iki yıl sürer. Köpek eğitimi çoğunlukla, köpeğe sahibini uyarmak için belli seslere tepki vermeyi öğretmekten oluşur. Mesela alarm çalar çalmaz yatağa atlar, kapı çaldığında sahibinin pantolonunu çekiştirir veya nazikçe elini tutarak sahibini zamansız bir ziyaretten haberdar eder. Bu, köpekten yararlanan kişi için genellikle belli bir yalnızlıktan kurtulmayı ifade eder (Royal Canin, 2018). Ayrıca eğitimlerinin bir parçası olarak bu köpekler sahibinin güvenliği için sahibine akıllı bir şekilde itaatsizlik etmeyi de öğrenirler. Örneğin, karşıdan karşıya geçerken sahiplerinin onlara verdikleri “ileri” komutunu duydukları zaman hareket etmek için eğitilmiş bu köpekler, görme engelli bireylerin sesini duyamayacağı bir araba geliyorsa “ileri” komutuna rağmen harekete başlamaz ve sahibinin can güvenliğini sağlarlar. Ayrıca bu özel köpekler, bu bireylerin engeli yollarda yürüken rehberlik ederler ve sahiplerinin yanından bir saniye ayrılmazlar. Bu köpekler, sahiplerini çevrede olan bitenden

haberdar etmeleri için eğitilirler. Örneğin alarm, kapı zili veya bebek ağlamasından haberdar olmaları için eğitilmiş köpekler sahiplerini uyarırlar (Bipati, 2018).

Sağlık Köpekleri

Kayıpları belirlemek için kullanılan ilk köpekler Mısırlılar tarafından eğitilmiştir. Çatışma bittiğinde bu köpekler savaş alanına salınarak yaralı askerleri aramışlar ve yerlerini belirleyerek yalama hareketi sergilemişlerdir. Daha sonraki sağlık köpekleri yirminci yüzyılda görülmüştür. Yaralıları bulmak ve onlara ait bir nesneyi geri getirerek yerlerini belirlemek için eğitilmişlerdi. Köpeklerini daha sonradan kurbanları bulmaya gönderecek olan ilk yardım çalışanları için bir asker miğferi çoğunlukla bir işaret olarak kullanılmıştır. Birçok rapor bu köpeklerin başarısından bahsetmektedir (Royal Canin, 2018). Son zamanlarda otizmi bireylerin toplum hayatına entegre etme bilincinin artmasıyla birlikte, bu bireyler için yardım/rehberlik hizmetleri için özel olarak eğitilmiş bu köpekler, bunaltıcı dönemlerinde bu bireylere en büyük dayanak noktası olurlar. Özellikle otizmi çocuklara en iyi arkadaşı olan patilerimiz, sakinleştirme ve tekrarlı istem dışı hareketlerin önüne geçmede büyük rol oynar (Bipati, 2018).

Bekçi Köpekleri

Köpeklerin olağanüstü koku duyuları ve sahiplerini korumak ve savunmak konusundaki eğilimleri, onları birçok kalenin, hisarın, korunan yerin ve müstahkem şehrin bekçileri haline getirdi. Bugünlerde köpekler çitle çevrilmiş yerlerde bekçi olarak durmaktadırlar (Yılmaz ve Ertuğrul, 2012).

Polis Köpekleri

Polis köpekleri, çok gelişmiş olan bekçilik etme ve kendilerini koruma içgüdüleri sayesinde hızlı bir şekilde zaferler elde etmekteydiler: bataklık ve diğer çalılıklar arasında saklanmış olan düşmanı saklandığı yerden çıkarmak ve polisleri pusulardan korumak ve düşman birliklerinin varlığından haberdar etmek için kullanıldılar. Özel eğitilmiş köpeklerin çok ileri koklama duyuları vardır. Örneğin, tek yumurta ikizlerini aileleri bile ayırt etmekte oldukça zorlanırken K9 köpekleri bu insanları ayırt etme yetisine sahiptir. Araştırmacılar, eğitimli köpeklerinin tek yumurta ikizlerinin arasındaki farklılıkları, burunlarını kullanarak söyleyebildiklerini keşfettiler (Fly Dog Turkey, 2018).

Uyuşturucu Arama Köpekleri

Köpeklerin burun delikleri boğazının arkasına kadar uzanır ve bu uzunluk bir köpeğe insandan 40 kat daha fazla koku alma özelliği kazandırır. Köpeklerin 300 milyon civarında koku alma reseptörü hücresi vardır ve bu sayı insanlarda sadece altı milyondur. Ayrıca bu özelliklerine ek olarak, bir köpeğin beyninin yüzde 35'i koku ile ilgili görevleri yapmaktayken insanların beyni sadece yüzde beşi bu görev için tanımlanmıştır. Bu özellikleri, uyuşturucu arama olaylarında neden bu kadar başarı olduklarının bir göstergesidir (Security Magazine, 2018).

Patlayıcı Arama Köpekleri

Seçilen köpeklerin ırkı uyuşturucu için kullanılan köpek ırkı ile aynıdır. Ancak ortaya çıkan risk dikkate alınarak köpeklerin daha sakin olması ve araştırmayı herhangi bir endişe olmaksızın yerine getirmesi gerekir. Favori cinsler Belçika çoban köpekleri (Belgian Shepherd Malinois) ve Alman çoban köpekleridir (German Shepherd Dogs) Özel eğitilmiş Patlayıcı Dedektör Köpekleri değişken ve dinamik güvenlik değişkenlerine ayak uydurmada operasyonel açıdan önemli avantajlar sağlar ve güvenlik yöneticisi için vazgeçilmez bir çözüm aracı olarak ön plana çıkarlar (Security Magazine, 2018).

Av Köpekleri

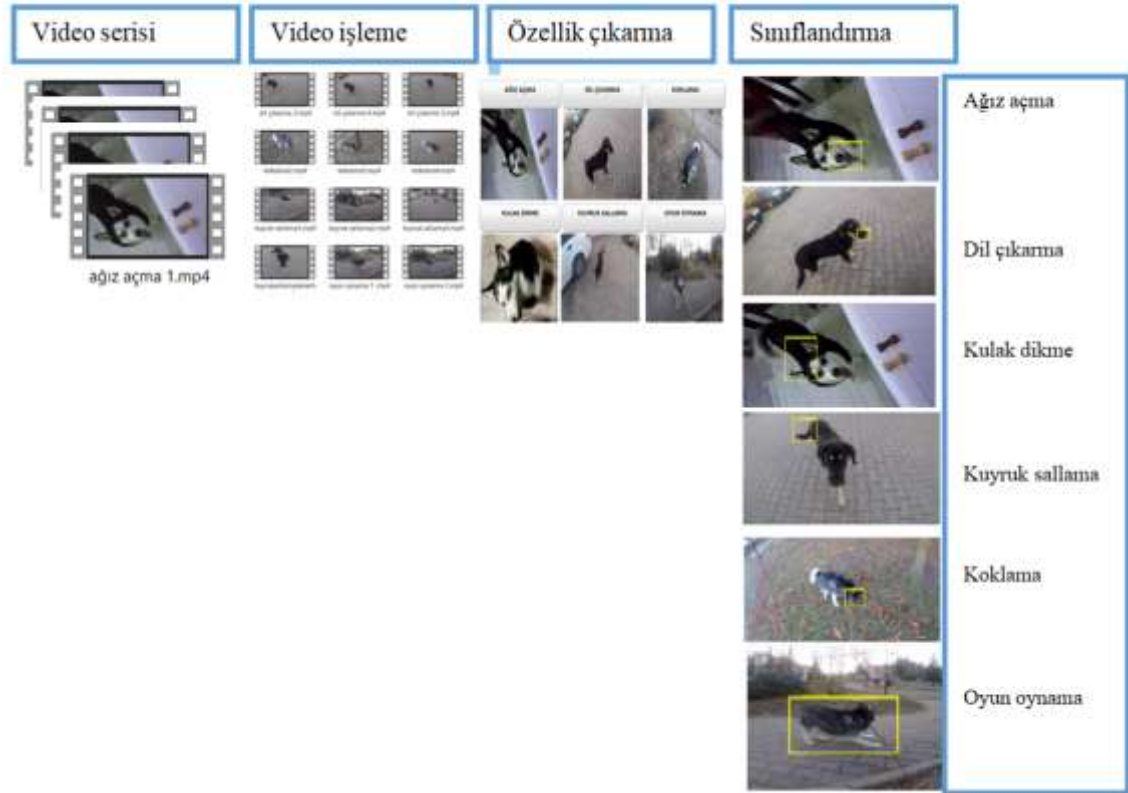
Av sporu uzun süreli ve her türlü hava şartları altında yapıldığından hem köpek hem de sahibi açısından mükemmel fiziksel kondisyon gerektirir. Ayrıca iyi bir av köpeği olabilmek için gerekli koku alma niteliklerinin yanı sıra karakterin güçlü olması, azim ve gözlem yeteneği de gerekir. Av yöntemleri, avın yapıldığı yer, oyun, hepsi köpeklerin fiziksel tiplerinin olağandışı bir şekilde farklılaşmasına neden olmuştur. Günümüzde belli bir kullanım ve alan için doğan bu ırklardan yüzlerce vardır. Teriyer köpekleri, su köpekleri, paket köpekleri, hedef veya av köpeklerinin hepsi kendilerine özgü fiziksel yapılar, koklama veya görme özelliklerine sahiptir. Avcının arkadaşı ve yoldaşı olan köpek olmadan av olmaz, aynı şekilde köpeğin her zaman kazanan olmadığı da bilinmektedir. Köpeğin sahip olduğu özgüven duygusu, bölgeyi bilmesi, hileli yaklaşımları fark etmesi, çok hassas koku alma duygusu, dayanıklılığı, kuvveti ve belli bir tipteki ava özgü yeteneklerini av süresince zekice kullanmaktadırlar. Bu

yetenekler sayesinde köpekler insanlar avlanırken en iyi yardımcıları olmayı başarmışlardır (Royal Canin, 2018).

Tüm hayvanlar, türlerine göre iyi kötü gelişmiş koku duyusuna sahiptir. Köpeklerde ise bu durum ırka göre değişir. Ancak eğitimin sonunda, köpek herhangi bir hatayı önlemek için rüzgârın kendisine getirdiği kokuları ayırt eder hale gelmiş olmalıdır. Hedef (ferma) köpekleri, “ara” komutunu aldıkları belli bir yerde, hareket etmeksizin bu komutu yerine getirmelidir ki avı korkutmamalı ve kaçırmamalıdır. Ayrıca öldürülen avı avcıya geri getirebilmelidir.

3. MATERYAL VE YÖNTEM

Önerilen tez çalışmasında kullanılan yöntemlere ilişkin blok diyagram Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Önerilen tez çalışmasının işlem adımlarını ve yöntemlerini gösteren blok diyagram.

Köpeğe giydirilebilen aksiyon kamerası ve sahibi tarafından kullanılabilen sabit kameralar ile köpeklerin doğal yaşam alanlarında iken videolar kaydedilmiştir. Oluşturulan video veri seti analiz edilerek tez çalışmasında belirtilen altı farklı hareket için daha küçük boyutlara sahip videolara dönüştürülmüştür. Bu sayede, hem eğitim süresinin kısaltılması hem de gereksiz içerikleri azaltılması sağlanmıştır. Kırpılan bu videolar çerçeve çıkarma programları kullanılarak çerçeveleri çıkarılmıştır. Elde edilen bu video ve çerçeveler eğitim veri seti ve test veri seti olmak üzere ikiye ayrılmıştır. Eğitim veri seti için video ve çerçevelerin %70’i kullanılırken test veri seti için % 30’u kullanılmıştır. Eğitim aşamasında eğitim veri setleri kullanılmıştır. Eğitim aşamasında özellik çıkarım işlemleri için derin öğrenme algoritmalarından CNN kullanılarak

çerçevelerden sayısal özellikler çıkarılmıştır ve bir dizi işleme tabi tutulmuştur. Son aşamada ise çıkarılan bu özellikler kullanılarak davranışların ortaya çıkarılması için yine bölgesel tabanlı-CNN (R-CNN) ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemlerinde test verileri kullanılarak her bir hareket için on adet çerçeve seçilmiştir. Seçilen bu çerçeveler ile eğitimi yapılan her bir hareket sınıflandırılmıştır.

3.1. Çalışma Alanı ve Köpekler

Tez süresince farklı zaman dilimlerinde, kamera yardımı ile insanlar ile temastan kaçınmayan iki farklı köpek üzerinde görüntü kayıt işlemleri yapılmıştır. Görüntü alınan köpekler sağlıklı kilolarında ve yaklaşık 2 yaşlarındadır. Bu görüntüler iki farklı kamera kullanılarak video verileri toplanmıştır. Bu kameranın birincisi insan tarafından kullanılarak direkt elde edilen veriler iken diğeri köpeğe giydirilmiş bir aktivite kamerası yardımıyla elde edilmiş görüntülerdir. Teknik ekipman temin edildikten sonra köpekler belirli süre izlenmiştir ve daha sonra altı farklı davranışın (ağız açma, dil çıkarma, koklama, kulak dikme, kuyruk sallama, oyun oynama) üzerinde tanıma ve sınıflandırma yapılmasına karar verilmiştir. Bu davranış biçimleri köpeklerin günlük hayatta çok sık yaptığı davranışlardan olmasına özen gösterilmiştir. Bunun asıl nedeni ise, davranış tanıma ve sınıflandırma işlemlerinin başarısını artmasındaki temel etken verilerin olabildiğince çok olmasına dayanmaktadır.


3.2. Veri Toplama ve Video Veri Setinin Oluşturulması

Önerilen tez çalışmasında, birden fazla köpekten, hem insan tarafından kullanılan hem de köpeğe giydirilebilir özelliğe sahip aktivite kamerası yardımıyla video parçaları elde edilerek çok kapsamlı bir veri seti oluşturulmuştur. Bu videolarda köpeklere ait statik, dinamik hareketleri ve duyguları gösteren videolar bulunmaktadır. Bu veri seti kullanılarak tanımlanan altı farklı (ağız açma, dil çıkarma, kulak dikme, kuyruk sallama, koklama, oyun oynama) köpek davranışlarının analizi gerçekleştirilmiştir.

Bu çalışmadaki tüm verileri toplamak için, GOPRO HERO5 giydirilebilir aksiyon kamerası ve köpeklerin sahipleri tarafından kullanılan sabit bir kamera kullanılmıştır. İnsanlar ile temastan kaçınmayan iki farklı köpek üzerinde görüntü kayıt işlemleri yapılmıştır. Görüntüler köpeklerin doğal ortamlarında yaşamlarını sürdürürken alınmıştır. Veri setinin oluşturulması için öncelikle köpeklerin doğal ortamında


davranışları incelenmiştir. Çalışmada farklı görüş açılarından köpekler için videolar alınarak köpeklerin sıklıkla sergilediği davranışlar belirlenmiş ve iki farklı köpek izlenerek veriler elde edilmiştir.

Alınan görüntüler üzerinden gerekli incelemeler yapıldıktan sonra, eğitim ve sınıflandırması yapılacak olan davranışlara karar verilmiştir. Elde edilen videolardaki tüm bölümler izlenerek incelenecek olan davranışların sergilendiği bölümler tespit edilmiştir. Bu incelenecek davranışların olduğu kısa bölümler video kırpma programları kullanılarak daha küçük parçalara ayrılmışlardır. Bu sayede tüm altı hareketler için daha anlamlı bölümlerden oluşan özelleştirilmiş veri seti elde edilmiştir. Minimum 3 saniye maksimum 8 saniye davranış içeriklerinin olduğu kısa videolardan maksimum sayıda çerçeve, jpg. formatında alınmıştır. Bu veri setlerinde oluşturulmuş olan oyun oynama hareketine ilişkin bazı videolara ait çerçeveler Şekil 3.2’de sunulmuştur.



Şekil 3.2. Oyun oynama içeriğine sahip videolardan alınan davranış çerçeveleri.

Şekil 3.3’de köpeklerde analizi yapılacak olan altı özel hareket için bazı örnek çerçeveler gösterilmiştir. Bu hareketler bir köpeğin günlük yaşamında birçok duygusunu ifade etmek için sıklıkla kullandığı davranış biçimleridir.



Şekil 3.3. Köpeklerde analizi yapılacak olan tanımlanmış altı özel hareket.

Köpeklerin duygusal durumlarını ve niyetlerini çevrelerindeki diğer kişilere iletmelerini sağlayan kendilerine has bir vücut dilleri vardır. Köpekler sesler ve sinyaller kullansalar da gönderdikleri bilgilerin çoğu, vücut dilleri, özellikle de yüz ifadeleri ve vücut duruşları aracılığıyla olur. Köpeğin ne söylediğini anlamak, köpeğinize ne olup bittiği hakkında fikir sahibi olmak, köpeğiniz endişeli ve sinirli olduğunda veya köpeğinizin sinirli olduğu ve birisine yapışmaya hazır olduğu zaman gibi birçok yararlı bilgi verebilir. Bu bilgileri anlamak için köpeğin yüzüne ve vücuduna bakmak gereklidir (ModernDog, 2018). Aslında duygu tanımlaması yapmamızda köpekler vücut dilini kullanarak bizlere birden fazla işaret sunmaktadırlar. Önerilen tez çalışmasında kullanılacak davranış biçimlerinin köpeğin hangi duygusuna karşılık gelebileceği Çizelge 3.1’de gösterilmektedir (Landsberg, 2018).

Çizelge 3.1. Köpeklerin altı farklı davranışı gösterdikleri eylemler için tanımlama (ASPCA, 2018).

Davranış Tipi	Tanımlama
Ağız Açma	Ağız açma hareketini köpek, sinirli olduğunda, kızdığında, yemek yeme isteğini göstermek için, sahibiyile oyun oynama isteğini göstermek için kullanabilir
Dil Çıkarma	Eğlendiğinde, sahibini karşıladığı anda, yemek yeme eyleminden sonra temizlenmek için kullanabilir
Kulak Dikme	Bir uyarı aldığında, tehlike hissettiğinde, karşısındakine kendi kararlığını gösterirken kullanabilir
Kuyruk Sallama	Rahat anında, yürüme esnasında, sahibinden bir beklentisi olduğunda, sevindiğinde bu tip hareketler kullanabilir
Koklama	Arama kurtarma esnasında, yiyecek ararken, yemek istediği yiyeceğin güvenli olup olmadığını anlamak için sık koklama hareketi yapabilir
Oyun Oynama	Sahibiyle eğlenmek istediğinde, rahat olduğu anlarda, mutluluğunu göstermek için bu tip hareketler yapabilir

Video veri seti:

CNN ile derin öğrenme işlem adımları, iki farklı köpekten, hem insan tarafından kullanılan hem de köpeğe giydirilmiş aktivite kamerası yardımıyla video parçaları elde edilerek çok daha kapsamlı bir veri seti oluşturulmuştur. Bu videolarda köpeklere ait statik, dinamik hareketleri ve duyguları gösteren videolar bulunmaktadır. Bu veri seti ile de köpek davranışlarının analizi gerçekleştirilmiştir.

Çizelge 3.2. Oluşturulan video veri seti hakkında detaylar

Veri Seti	Toplam altı hareket için
Video adedi	160
Video süresi	1020 sn (mp4. format, 1920x1080 boyut)
Çerçeve sayısı	Yaklaşık her hareket için 3000 adet (1920x1088 boyut, 96dpi çözünürlük)
Eğitim çerçeve sayısı	Yaklaşık her hareket için 2100
Test çerçeve sayısı	Yaklaşık her hareket için 900

Video işleme:

Bu aşamada, köpeğin günlük yaşantısından ilk etapta uzun süreli videolar elde edilmiştir. Daha sonra bu videolar izlenerek incelenecek davranışları içeren daha küçük videolar elde edilmiştir. Bunun nedeni, eğitim aşamasını daha kısa süreye indirmektir. Bu kısa süreli videolar kullanılarak video çerçevelerinin çıkarılması, kenar, köşe ve diğer bölgelerin tespit edilmesi sağlanmış ve devamında video işleme algoritmalarıyla bu özellikler kullanılarak eğitim aşamasında sırasıyla işlenmiştir. Bu aşamada temel görüntü işleme filtreleri, histogram işlemleri, görüntü ön-işleme teknikleri kullanılmıştır.

Özellik çıkarımı ve seçimi:

Özellik çıkarımı aşamasında, köpeklerin davranışlarının analizinin yapılabilmesi ve sınıflandırılabilmesi için video üzerinde sayısal özelliklerin çıkarılması/ölçülmesi gerekmektedir. Özelliklerin çıkarılması için hibrit özellik çıkarım algoritmalarından yararlanılmıştır. Çıkarılan özelliklerin sayısı çok fazla olduğu durumlarda, bunlar içerisinden en uygun olanlarının seçimi gerçekleştirilmiştir. Nitekim köpeğin günlük hayatında çok daha farklı davranış biçimleri sergilediği düşünülürse önerilen tez çalışmasının kapsamı sadece altı hareket ile sınırlandırılmıştır.

Sınıflandırma ve davranış analizi:

Önerilen yöntemin son aşamasında ise çıkarılan özellikler kullanılarak köpeklerin belirlenen davranışlarının analizi gerçekleştirilmiştir. Bu aşamada köpeklere ait statik ve dinamik hareketleri incelenmesi hedeflenmektedir. Veri seti oluştururken köpeğin günlük hayatı izlendiğinde sıklıkla yaptığı eylemler olduğu tespit edilmiş ve bu

eylemlerden daha fazla çerçeve elde edileceği düşünülerek tercih edilmiştir. Fazla sayıda veri seti oluşturulması öğrenmeyi olumlu etkileyen en önemli özelliktir. Öğrenme sürecinde CNN derin öğrenme mimarisi kullanılarak eğitim ve sınıflandırılması sağlanmıştır.

Web tabanlı köpek takibi:

Giydirilebilir aksiyon kamesına ek olarak, GPS sinyalleri ile köpeğin yaşam alanlarının incelenmesine imkan veren modüler gömülü bir sistem tasarlanmıştır. GPS verileri web servisi aracılığıyla kaydedilmiştir. Hazırlanan web sitesi sayesinde veriler Google MapsApi kullanılarak harita üzerinde anlık ve bölgesel olarak işaretlenmiş ve kullanıcıya sunulmuştur. Bu sistemin amacı izlenen köpeklerin konumlarının takip edilmesi ve kontrol edilmesi hedeflenmiştir.

3.3. Derin Öğrenme

Derin Öğrenme algoritmaları yapay sinir ağlarının (YSA) yapısal olarak daha karmaşık hali olarak düşünülebilir. YSA algoritmaları insandaki öğrenme işleyişinden hareketle geliştirilmiştir. Biyolojik sinir sisteminde bulunan nöronların birbirleri ile ilişki kurması gibi YSA sistemlerinde de nöron şeklinde tanımlanan yapılar birbirleri ile bağlantılı olacak şekilde modellenmişlerdir. Algoritmanın bu şekilde öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahip olacağını düşünmüşlerdir (Koppula ve Saxena, 2013). Derin Öğrenme algoritmalarının makine öğrenmesindeki var olan algoritmalarından ayrılan yönü, birçok katmandan oluşmasıdır. Bu katman sayısı yapısal olarak değiştirilebilir ve farklı yöntemler ile karma modeller oluşturulabilir.

Derin öğrenme ağları, çok yüksek miktarda karmaşık veriyi işleme kapasitesine, çok yüksek hesaplama gücü ve hızı olan GPU donanımları sayesinde ulaşmıştır. Ayrıca yüksek veri ve hesaplama gücü olanaklarına sahip büyük teknoloji firmaları (Google, Facebook, Microsoft, Nvidia vb.) tarafından da kullanılıp ürünlerine entegre edilmektedir. Aynı zamanda bu teknoloji firmaları kendi Derin Öğrenme yazılım kütüphanelerini geliştirici topluluklara da açarak bu alandaki hızlı ilerlemeye destek olmaktadır.

Derin öğrenme algoritmaları ve GPU teknolojisindeki gelişmelerle birlikte robotik, görüntü işleme, ses ve sinyal işleme gibi alanlardaki imkânsız gibi gözükten

problemleri rahatlıkla çözebilir. Son yıllarda güçlü GPU'lar ve büyük veri setleri sayesinde derin öğrenme algoritmaları derin sinir ağlarını kullanmaktadır. Derin sinir ağları paralel algoritmalarıdır. Yani aynı anda birden fazla algoritma işlem yapabilir. Bu paralellik derin öğrenme ağlarının ihtiyacı olan işlem süresini azaltmak için binlerce çekirdekten oluşan GPU'lar için bir avantajdır (Karpathy, vd., 2014).

MATLAB ile derin öğrenme uygulamaları genellikle global veri setleri üzerinde ön eğitilmiş ağlar ile yapılabilmektedir. Bu bağlamda CIFAR-10 / CIFAR-100 veri seti örnek verisetlerinden birisidir. CIFAR-10 için veri büyütme olmaksızın son teknoloji yöntemleriyle, yaklaşık %94'lük insan seviyesinde sınıflandırma doğruluğuna benzer şekilde başarı elde edilebilir. CIFAR-100 için bu başarı oranı, veri büyütme olmaksızın yaklaşık %20'dir (DenseNet, 2018). Mevcut başarı oranları değerlendirildiğinde önerilen tez çalışmasında da CIFAR-10 veri setinin kullanılmıştır (Sichkar, 2018).

CIFAR-10 veri seti, sınıf başına 6000 görüntü ile 10 sınıfta toplam 60000 32x32 renkli görüntü, 50000 eğitim görüntüsü ve 10000 test görüntüsü bulunmaktadır. Veri seti, her biri 10000 görüntü içeren beş eğitim serisine ve bir test partisine ayrılmıştır. Test partisi, her sınıftan tam olarak rastgele seçilmiş 1000 görüntü içerir. Eğitim grupları, kalan görüntüleri rastgele sırada içerir, ancak bazı eğitim grupları bir sınıftan diğerine göre daha fazla görüntü içerebilir. Bunlar arasında eğitim grupları her sınıftan 5000 görüntü içerir. Bu görüntü kümesi Şekil 3.4'te gösterilmektedir (Sichkar, 2018).



Şekil 3.4. MATLAB'de CIFAR-10 resim kütüphanesi.

3.3.1. Derin Öğrenme Ağı İşlem Adımları

CNN bilgisayarlı görü uygulamalarında kullanılmak üzere geliştirilmiş çok katmanlı yapay sinir ağlarının özel bir modelidir (Sichkar, vd., 2018). Yapısında konvolüsyon, havuzlama ve tam bağlantı katmanı gibi kendine özgü görevleri olan ayrı katmanları barındırır. Bunlar birbirini takip edecek şekilde dizilerek CNN modelini oluştururlar. Bu yapının ilk kısımlarında öznitelik çıkartım işlemleri gerçekleştirilirken sınıflandırma işlemi ise son katmanlarda gerçekleşir (Nie, vd., 2011).

Derin öğrenme ağı yapısı kullanırken öncelikle bir model belirlenmesi gerekmektedir. Örneğin, KNN sınıflandırma algoritmasında k değerinin ne olacağına modeli tasarlayan kişi karar vermektedir. Benzer şekilde SVM algoritmasında hangi kernel fonksiyonunun kullanılacağına da tasarımcı karar verir. Nitekim derin ağ modellerinde seyreltme (dropout) değerine, katman sayısına, nöron sayısına modeli tasarlayan kişi karar vermektedir. Genelde bu parametreler için hangi tercihte bulunulacağı başlangıçta açık ve kesin değildir; probleme, veri setine vd. gibi etmenlere göre değişiklik göstermektedir. Bu nedenle parametrelerin seçimi modeli tasarlayan kişiye bırakılmıştır. Ne olması gerektiği, modeli tasarlayan kişiye bırakılmıştır. Veri

setine göre deęişiklik gösteren parametreler hiper-parametre (hyperparameters) olarak adlandırılmaktadır. Hiper parametrelerin seçimi genelde tasarımcının sezgisine, daha önceki problemlerden elde edilen tecrübelerle, farklı alanlardaki uygulamaların kendi problemimize yansımalarına, güncel eğilimlere, model içindeki tasarım bağımlılığı vd. göre deęişmektedir. Bununla birlikte son zamanlarda problemin çözümü için en uygun hiper parametre grubunun en optimum şekilde seçilmesine yönelik farklı teknikler ortaya atılmaktadır. Bu problemlere çözüm bulacak yöntemlere derin öğrenme iyileştirme başlığı altında incelenecektir.

Evrışimsel sinir aęlarında her bir katmanda matris üzerinde işlem yapan kerneller kullanılmaktadır. Bunlar basit Gabor filtreleri gibidir. Bu kernellerin boyutu öğrenme üzerinde hayli etkilidir. Çünkü kernel boyutu ile ne kadar genişlikte verinin birbirini etkileyeceğine karar verilmektedir. Genellikle 3x3, 5x5, 7x7 kerneller kullanılmaktadır. Tek sayılardan oluşmasının sebebi: kenar bulurken işlem yapılan pikselin sağına-soluna, üstüne-altına bakılabilmesi içindir. Büyük boyutlu kernel kullanılması evrişim uygulandıktan sonra oluşacak resmin küçük olmasına neden olacaktır. Bu durumda bilgi kaybına yol açtığından genelde 3x3 gibi küçük boyutlu kernel kullanılmaktadır.

3.3.1.1. Konvolüsyonel sinir aęları (CNN)

Derin konvolüsyonel sinir aęları, derin öğrenme algoritmalarının özelleştirilmiş bir biçimidir. Konvolüsyonel sinir aęları geleneksel makine öğrenme tekniklerindeki boşlukları doldurarak problemleri çözme şeklini deęiştirmiştir. Konvolüsyonel sinir aęları sadece görüntü sınıflandırması yapmak için kullanılmazlar. Bu aęlar, istenileni manuel özellik çıkarma ihtiyacını ortadan kaldırarak ham görüntüden çıkarırlar. Bilgisayarlı görü uygulamalarında genellikle görüntü sınıflandırılmasından daha fazlası gerekir. Nesne tanıma uygulamaları için en son makine görüşü teknikleri ve GPU'ların nasıl verimli kullanılacağı iyi bilinmelidir.

Makine öğrenmesi konularındaki problemlerin çözümünde son yıllarda büyük doğruluk oranı ve hız ile kendinden çokça söz ettiren derin öğrenme kullanılarak görüntü sınıflandırma işlemi yöntemlerinde sıklıkla tercih edilmiştir. Biyolojiden ilham alınarak üretilen çok katmanlı algılayıcıların bir türevidir (Nguyen, vd., 2015). Literatürde ve uygulamada derin öğrenme teknięi kullanılarak birçok çalışma yapılmış ve başarılı sonuçlar elde edilmiştir. Derin öğrenmenin özelleşmiş bir mimarisi olan CNN özellikle görüntü işlemede oldukça başarılıdır (Rodin, vd., 2018).

CNN, eğitilebilen birçok katmandan oluşmaktadır. Her katmanın kendi içinde öznelik havuzlama katmanı, filtre banka katmanı ve doğrusal olmayan katman olmak üzere üç katmanı vardır. Geleneksel ileri beslemeli sinir ağlarında bir katmandaki bütün nöronlar bir sonraki katmanın bütün nöronlarına bağlıdır. Bu tür bağlı katmanlara tam bağlı katman (Fully Connected Layer) denir. Bu katman kendinden önceki katmanın tüm alanlarına bağlı olduğu için bu şekilde adlandırılmıştır. Oluşturulan mimari yapılarına göre bu katmanın sayısı değişebilir. CNN mimarisinde en son katmanın üretmiş olduğu matris boyutu $25 \times 25 \times 256 = 160000 \times 1$ ve tam bağlantılı katmandaki matris boyutu 4096×1 olarak seçilirse toplamda 160000×4096 ağırlık matrisi oluşur. Yani her bir 160000 nöron 4096 nöron ile bağlanmaktadır. İşte tam bu nedenle tam bağlantılı katman olarak isimlendirilir.

CNN'de tam bağlı katmanlara ek olarak çıkışı üretmesi için giriş katmanına konvolüsyon uygulanır. Bu, giriş katmanındaki bütün bölgelerin bir sonraki katmanda bulunan nöronlara bağlı olduğu lokal bağlantılara neden olur. Her katmanda farklı filtreler uygulanır ve sonunda bunların sonuçları birleştirilir. Eğitim boyunca CNN, filtrelerin içeriğini (öznelikleri) gerçekleştirmesi istenen işleme göre kendisi otomatik olarak öğrenir. Böylece baştan sona doğru her katmanda görüntüye ilişkin basitten karmaşığa öznelikler öğrenilmiş olur. Filtre banka katmanında değişik öznelik çıkarılması işine yarayan birçok çekirdek bulunmaktadır. Havuzlama katmanında elde edilen her öznelik haritası ayrı ayrı ele alınır. Şekil 3.8'de herbir özellikler için komşu değerinin ortalaması veya maksimum değerinin elde edilmesini sağlamaktadır. Ağda üç evrişim katmanı, bu katmanını takip eden üç pooling (havuzlama) katmanı ve en alt iki katmanda tam bağlantılı katman bulunmaktadır. Bu yapıda giriş resimleri adım adım parçalara ayrılır. Her parçaya filtre uygulanır. Filtre işleminden sonra resimde küçülmeler meydana gelir. Bu işlem sonucunda elde edilen pikseller anlamlandırılarak problem çözülmeye ve davranışlar tespit edilmeye çalışılır.




Şekil 3.5. Evrişimsel sinir ağı (CNN) yapısı.

R-CNN (Region-Based Convolutional Neural Networks, Bölgesel Tabanlı Evrimsel Sinir Ağı)

Son zamanlarda en çok kullanılan derin öğrenme modelleri Alex Net (2012), ZF Net (2013), VGG Net (2014), GoogLeNet (2015), Microsoft RestNet (2015), CNN (R-CNN (2013), Fast R-CNN (2015), Faster R-CNN (2015)) modelleridir. Bu modellerin her biri derin öğrenmede temel taşları olarak kabul edilmektedir (Girshick, 2015).

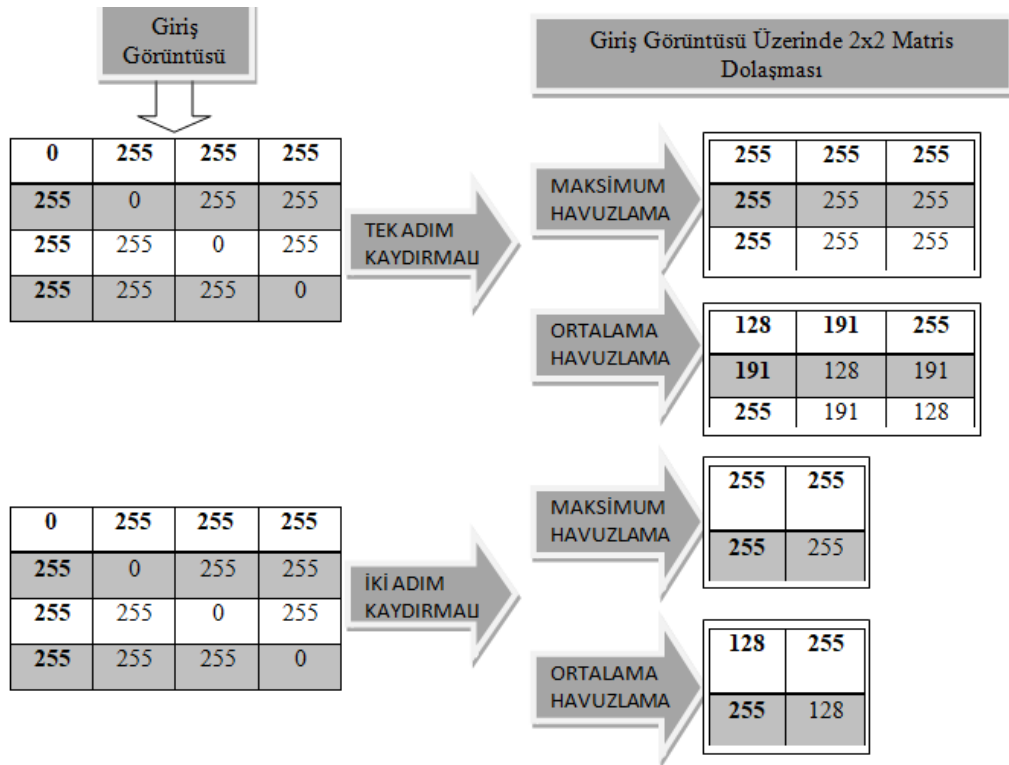
Görüntü sınıflandırma işlemi, genellikle bir görüntüdeki nesnenin tahmini üzerine çalışmaktadır. Nesnenin görüntünün neresinde olduğu ve kapladığı sınırların tespiti ise nesne tanımlama işlemidir. Nesne tanımlama için derin öğrenmede R-CNN modeli ilk kez Girshick (2015) tarafından tasarlanmış olup bu mimarinin benzeri bir yapı bu çalışma için uygulanarak Şekil 3.6'da gösterilmiştir.



Şekil 3.6. R-CNN modeli.

Bu mimari Şekil 3.6'da gösterildiği gibi başlıca 4 bölümden oluşmaktadır. Birinci bölümde görüntüler alınır. İkinci bölümde ise Seçici Arama (SA) ile bölge önerileri yapılır. SA, bir nesneyi ihtimali yüksek olan 2000 farklı bölge üretme işlevi gerçekleştirir. Üçüncü bölümde her bir bölge önerisi AlexNet'te benzer şekilde tasarlanmış CNN mimarisine verilir. Bu işlem hattını eğitmek son derece zordur ve ortalama görüntü başına 50 saniye gibi bir zaman almaktadır. Bu sorunların üstesinden gelmek için Fast R-CNN modeli geliştirilmiştir (Girshick, 2015). Bu mimaride öncelikle her bir görüntü için yaklaşık 2000 kez CNN çalıştırmak yerine tek bir kez CNN çalıştırıp 2000 öneri arasında bu hesaplamaların paylaşımı yapılmaktadır. Böylelikle eğitim ve test süresi kısaltılmıştır. Hem R-CNN hem de Fast R-CNN'nin sergilediği karmaşık eğitim hattını iyileştirmek için Faster R-CNN tasarlanmıştır. Bu işlemi son konvolüsyon katmanından sonra bir bölge öneri ağı (Region Proposal Network (RPN)) ekleyerek gerçekleştirmiştir (Ren, S., vd., 2017).

tutarak yükseklik ve genişlik bilgisini azaltır fakat aynı zamanda boyutta azalma durumu bilgi kaybına yol açar. Bu kayıp aslında ağ için iki nedenden dolayı istenilen bir durumdur. Birincisi, bir sonraki ağ katmanları için daha az hesaplama yükü oluşturur, ikincisi ise sistemin ezberlemesini önler. Kısacası bu katmanın en büyük faydası derin öğrenme ağındaki hesaplama karmaşıklığını azaltır. Havuzlama katmanları girdi olarak verilen resmin alt örnekleme işlemini yapar ve her filtrenin sonucuna maksimum değerlerini (maksimum pooling), minimum değerlerini (minimum pooling), veya değerlerin ortalamasını (average pooling) alarak işlem yapar. Bu katmanda genellikle maksimum havuzlama yöntemi daha başarılı sonuçlar vermektedir. Havuzlama işlemi, konvolüsyon katmanı sonucu oluşan filtre adedince görüntülerin hepsi için gerçekleştirilir. Seçilen havuzlama boyutu içindeki piksellerin en büyüğünü çıkışa aktarır. Şekil 3.8’de 2x2 boyutlu pencere için maksimum havuzlama (filtrelerde oluşan değerlerin en yüksekinin alınması) işlemi 2 adım (piksel) kaydırılarak uygulanmıştır. İlgili 4 elemanın olduğu alandaki en büyük değeri çıkış matrisine aktarılır. Havuzlama işleminin sonucunda sabit boyutlu bir matris elde edilmekte ve çıkış boyutu önemli ölçüde düşürülmektedir.




Şekil 3.8. Havuzlama işlemi.

Aktivasyon fonksiyonu

Yapay sinir ađları uygulamalarında kullanılan çok farklı özelliklere sahip aktivasyon fonksiyonları vardır. Aktivasyon fonksiyonun seçimi sistemin başarısı için büyük öneme sahiptir. Bu nedenle CNN uygulamalarında ReLU aktivasyon fonksiyonu başlangıç için iyi bir seçenek olacaktır.

Relu(Düzleştirilmiş Doğrusal Birim Katmanı) Aktivasyon Fonksiyonu

ReLU, düzeltilmiş doğrusal ünite anlamına gelir ve bir tür aktivasyon fonksiyonudur. Matematiksel olarak $y = \max(0, x)$ olarak tanımlanır. Görsel olarak, Şekil 3.9'deki gibi görünür.



Şekil 3.10. ReLU aktivasyon fonksiyonu.

Şekil 3.11'den anlaşılacağı gibi, tüm pozitif değerler için doğrusal özellik gösterirken diğer tüm negatif değerler için sıfır değerine sahiptir. Bu katmandan önce kullanılan konvolüsyon katmanında belirli matematiksel işlemler yapıldığı için ađ doğrusal bir yapıdadır. Bu derin ađı doğrusal olmayan bir yapıya sokmak için bu katman uygulanır. Linerliğin verdiği diğer özellik ise Sigmoid veya tanh fonksiyonlarında doyum (saturasyon) ve düzlemsellik problemlerinden kaynaklanan yok edici gradyan problemine sahip değildir. Biraz daha detaylı anlatmak gerekirse negatif değerler için sistem sıfır ürettiği için fonksiyonda 'Sparsity' (kayıp datalar) etkindir. Sistem aslında yapay sınırları taklit etmeye çalışır ve aslında biyolojik sinir ađı yapısına benzer. Biyolojik sistemimizde her problem için her zaman devreye giren özel bir alan vardır ve bir sorun için tüm vücudumuz devreye girmesi halinde kaos oluşacağını düşünürsek, daha özelleştirilmiş hücre yapılarına ve görevlere sahip

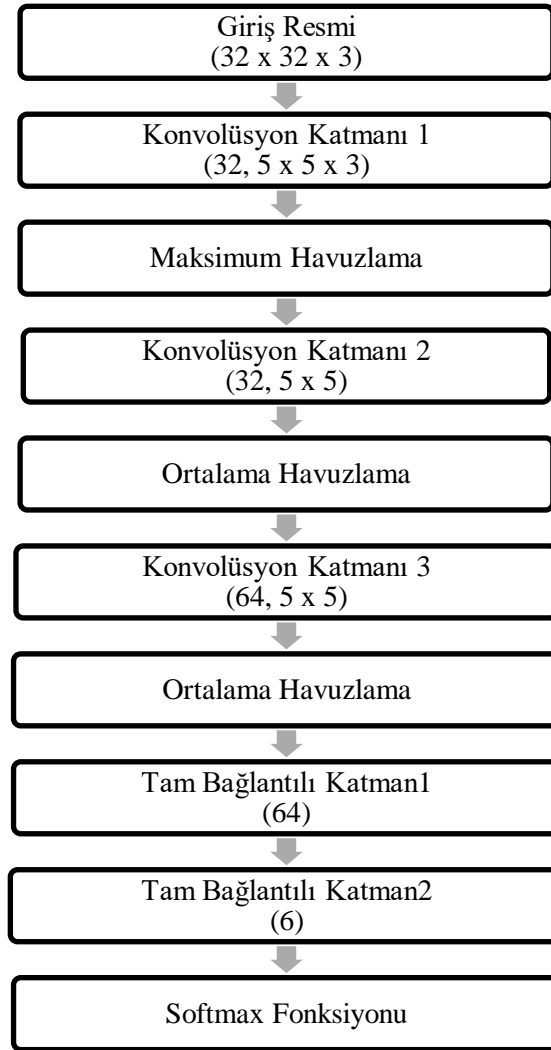
birimlerden oluřurlar. Bu katmanın kullanılması ile ađ daha hızlı öğrenir ve eğitim aşaması daha kısa sürer. Bu nedenle sistem daha kararlı çalışır.

Kayıp veriler, genellikle daha iyi kestirim gücüne ve daha az aşırı uyum (overfitting)/gürültüye sahip daha başarılı modellerle sonuçlanır. Önerilen tez çalışmasında gerçekleştirilen çalışmalar ve oluşturulan veri setleri hakkında daha da detaylı olarak dördüncü bölümde bahsedilecektir. Bu veri seti aslında seyrek ađlara bir örnektir. Seyrek bir ađda nöronlar aslında problemin anlamlı yönlerini işlemesine odaklanır. Önerilen tez çalışmasında köpek hareketleri var ve yaptığımız şey asıl hareketin gerçekleştiđi alanın işaretlenmesi ve matematiksel deđerler oluşturulmasıdır. Bu nedenle seyrek bir ađ, hesaplanması gerekenden daha az veri içerdiđi için yoğun bir ađdan daha hızlıdır.

4. DERİN ÖĞRENME TABANLI KÖPEK DAVRANIŞLARININ ANALİZİ VE SINIFLANDIRILMASI

Tezin bu aşamasında kullanılarak köpek videolarından davranışların analizi ve sınıflandırılması gerçekleştirilmiştir. Önerilen CNN modelinin yapısında konvolüsyon, havuzlama ve tam bağlı gibi kendine özgü görevleri olan ayrı katmanları bulunmaktadır. Bunlar birbirini takip edecek şekilde dizilerek CNN mimarisi oluşturulur. Bu yapının ilk kısımlarında öznitelik çıkartım işlemleri gerçekleştirirken sınıflandırma işlemi ise son katmanlarda gerçekleşir (Nie, vd., 2011).

Önerilen tez çalışmada üç CNN katmanı, üç pooling işlemi ve tam bağlantılı katman olmak üzere toplamda beş katmanlı bir CNN mimarisi oluşturulmuştur. Oluşturulan beş katmanlı CNN modeli hazırlanan eğitim veri seti ile eğitilmiştir. Ayrıca son tam bağlantılı katmanın çıkışı altı yollu bir “softmax” ile beslenmiştir. Yapay sinir ağı modelinin çıktısı olarak verdiği skor değerler normalize edilmemiş değerlerdir. Softmax bu değerleri normalize ederek olasılık değerlerine dönüştürmektedir. Olasılık değerine dönüştürme işlemini istatistikte sıkça kullanılan maksimum olasılıklı (maximum likelihood) fonksiyonuyla yapmaktadır. Değerler çok büyük değerler olduğu için olasılık fonksiyonun logaritmik değerini alarak dağılımın yapısını korumaktadır. Özetle softmax fonksiyonunda amaç test verisinin doğru sınıfı için logaritmik olasılık (log likelihood) değerini maksimize etmektir. Loss fonksiyonunda amaç ise negatif olasılıklı (negative likelihood) minimize etmektir yani en az farka sahip, en çok benzerliğe sahip sınıfı bulmaktır (Stanford University, 2018). Oluşturulan CNN yapısına ait akış şeması Şekil 4.1’de görülmektedir.



Şekil 4.1. Kullanılan CNN'nin mimarisi.

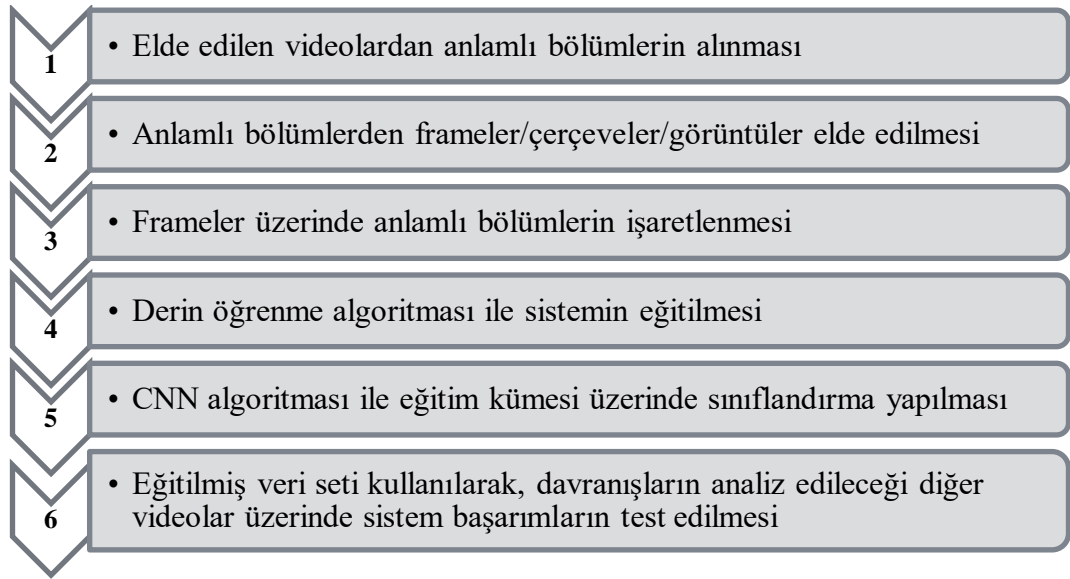
Her bir konvolüsyon katmanı CNN modelinin ana yapı taşıdır ve her bir resmin özelliklerini saptamak için kullanılmaktadır. Konvolüsyon katmanı, görüntüdeki düşük ve yüksek seviyeli özellikleri çıkarmak için resme bazı filtreler uygulamaktadır. Bu filtre kenarları algılayacak genellikle çok boyutlu bir filtredir ve piksel değerleri içerirler. $5 \times 5 \times 3$ boyutlarında tercih ettiğimiz matris, yükseklik ve genişliğini 5 ile derinliğini 3 ile ifade edilmiştir. CNN ağında birden fazla konvolüsyonel katmanı birden çok özelliği tespit etmek içindir ve birden fazla özelliği tespit etmek için ise birden fazla filtre kullanılmaktadır. İlk konvolüsyon katmanında ilk filtreyi uyguladığımızda, bir özellik haritası oluşur ve bir özellik türü tespit edilmiş olur. Ardından, ikinci bir filtre kullanıp başka bir özellik türünü algılayan ikinci bir özellik haritası oluşturur. CNN'nin ilk

aşamalarında, ilk filtreleri uygularken diğer katmanlar için mümkün olduğunca çok fazla bilgiyi korumamız gerekmektedir. Bu nedenle padding (ekleme) kullanılır. Özellik haritası çıkarılırken resimlerin matris boyutlarının filtreleme işlemleri nedeniyle küçülmektedir. Bu nedenle orijinal resmin boyutunu korumak için sıfır ekleme işlemi yapılmaktadır. Devamında her bir katmanda havuzlama işlemlerinin yapılmasının nedeni, ağırlık sayısının azaltılmasını ve uygunluğun kontrol edilmesini sağlamaktır. Havuzlama katmanı yerine konvolüsyon katmanında daha büyük bir padding işlemi tercih edilebilir. Tüm bu katmanların sayısı ve ard arda eklenmesi öğrenme süresini başarısını etkilemektedir.

Öğrenme transferi, büyük bir veri kümesi modelinden öğrenilmiş ağırlıkların alındığı ve bunların çeşitli sabit katmanlara uygulandığı, kalan katmanların tekrar eğitildiği veya ağırlık ayarlarının yapıldığı, yaygın olarak kullanılan bir derin öğrenme tekniğidir. CNN yapısı oluştururken eğitim için bir veri kümesine ihtiyaç duyulur ve bu veri kümesi yeteri kadar büyük değilse oluşturulan ağ teste tabi tutulduğunda düşük bir doğruluk oranı verir. Bu durumda eğitim veri kümesinin büyütülmesi yani etiketli veri sayısının artırılması gerekir. Fakat bazı durumlarda bu mümkün değildir ve sınırlı sayıdaki etiketli eğitim verisi ile çalışmak zorunda kalınabilir. Bu koşullarda en iyi doğruluk derecesine sahip sonuçların öğrenme transferi ile elde edildiği görülmüştür. Yani öğrenme transferi, küçük veri kümeleri ile yüksek doğruluk derecesine sahip sonuçlar alınmasını sağlayabilir.

Davranış modellemesinin doğal fiziksel sistemlerden, canlı organizmaların davranış çalışmasına, yaşam benzeri karaktere, robot hareket kontrolüne ve video dizilerinden otomatik davranış analizine kadar kullanım alanları bulunabilir. Burada, otomatik davranış analizi için temel olan davranış modellemesi, özellik çıkarma tanımının görevlerinin yanı sıra bir üretken davranış modelinin yaratılmasını da kapsar. Davranışının incelenmesinde genel amaç, yalnızca ne olduğunu açıklayan bir tanım üretmek değil, gelecekteki olayları tahmin etmek için kullanılabilir (Bagherinezhad, vd., 2018).

Önerilen tez çalışmasında köpek davranışlarının CNN ile analiz edilmesi için takip edilen işlemlerin akış şeması Şekil 4.2’de sunulmuştur.



Şekil 4.2. Köpek davranış analizi işlemlerinin akış şeması.

4.1. Derin Öğrenme Algoritması ile Sistemin Eğitilmesi

Köpeğin davranışını tespit etmek için CNN derin öğrenme uygulamalarında yaygın olarak kullanılan transfer öğrenme iş akışını kullanır. Transfer öğrenmesinde, geniş bir resim koleksiyonu üzerine eğitilmiş bir ağ, yeni bir sınıflandırma veya tespit görevini çözmek için başlangıç noktası olarak kullanılır. Bu yaklaşımı kullanmanın avantajı, önceden eğitilmiş ağın çok çeşitli görüntülere uygulanabilecek zengin bir dizi görüntü özelliği öğrenmiş olmasıdır. Bu öğrenme, ağa ince ayar yaparak yeni göreve aktarılabilir. Bir ağ, orijinal görev için öğrenilen özellik sunumlarının yeni görevi destekleyecek şekilde hafifçe ayarlandığı şekilde ağırlıklardaki küçük ayarlamalar yaparak ince ayar yapılır. Bu amaçla CNN ağının eğitilmesi için kullanılan parametreler Çizelge 4.1’de sunulmuştur.

Çizelge 4.1. CNN ağının eğitilmesi için kullanılan parametreler

15x1 Katmanlı Dizi	Açıklama
Giriş resmi	32x32x3 'zerocenter' normalizasyonlu resimler
Konvolüsyon	32x5x5 konvolüsyonu
ReLU Aktivasyon Fonk.	ReLU aktivasyon fonksiyonu
Maksimum Havuzlama	3x3 maksimum havuzlama
Konvolüsyon	32x5x5 konvolüsyonu
ReLU Aktivasyon Fonk.	ReLU aktivasyon fonksiyonu
Maksimum Havuzlama	3x3 maksimum havuzlama
Konvolüsyon	64x5x5 konvolüsyonu
ReLU Aktivasyon Fonk.	ReLU aktivasyon fonksiyonu
Maksimum Havuzlama	3x3 maksimum havuzlama
Tam Bağlantı Katmanı	64 tam bağlantılı katman
ReLU Aktivasyon Fonk.	ReLU aktivasyon fonksiyonu
Tam Bağlantı Katmanı	10 tam bağlantılı katman
Softmax Fonksiyonu	Softmax fonksiyonu
Classification Output	Olasılık Değeri hesaplama

Ağ eğitim algoritması, Momentum (SGDM) ile 0.001'lik bir başlangıç öğrenme oranı ile Stokastik Gradyan Descent'i (Olasılıksal Dereceli Azalma) kullanır. Eğitim sırasında, ilk öğrenme oranı her sekiz adımda bir azaltılır. Olasılıksal dereceli azalma, verimlilik ve kod ayarlama için birçok uygulama kolaylığı sunmaktadır. Dereceli azalma, her bir adımda (step) bütün veri setini gezdikten sonra güncellenebiliyor. Olasılıksal dereceli azalmada amaç, her bir adımda veri setindeki her bir örneği gezdikten sonra veri setini güncellemektir. Tüm veri setinin bir ileri yönde bir de geri yönde gezinmesi ve tüm ağdan geçmesi işlemine epok denir. Eğitim algoritması kırk epok için çalıştırılmıştır. Eğer örnekleme kümesi ne kadar büyükse geçiş o kadar zaman almaktadır. Örneğin, 1000 adet veriden oluşan bir veri seti için paket boyutu 500 seçilirse bir epoku tamamlamak için iki iterasyon gereklidir (Kurt, 2018).

4.2. Elde Edilen Videolardan Anlamlı Bölümlerin Alınması

Bu aşamada kameralar ile farklı zamanlarda alınan büyük video parçalarından köpeklerin anlamlı davranışlarının bir uzman eşliğinde videolardan çıkarılması sağlanmaktadır. Bu video özelleştirme işlemi eğitim sırasında, eğitim süresinin kısalmasına önemli ölçüde fayda sağlamaktadır. Özelliklerin olduğu bölümlerin çıkarıldığı video çerçeveleri Şekil 4.3'te gösterilmektedir.



Şekil 4.3. Özelleştirilmiş video içerikleri.

4.3. Anlamlı Bölümlerden Çerçevesel/Görüntüler Elde Edilmesi


Bu aşamada anlamlı video parçalarından bilgisayarlı görü sisteminin tasarlanması için video çerçeveleri elde edilmektedir. Bu çerçeveler köpeğin davranışlarının analizi için video sahnesinde köpeğin olduğu bölümlerin yakalanması amacıyla kullanılacaktır.

Ağız açma hareketi için oluşturulmuş veri setinden örnekler Şekil 4.4'te gösterilmiştir.



Şekil 4.4. Köpeğin ağız açma hareketleri sırasında alınan videolardan elde edilen çerçeveler.

Dil çıkarma hareketi için oluşturulmuş veri setinden örnekler Şekil 4.5'te gösterilmiştir.



Şekil 4.5. Köpeğin dil çıkarma hareketleri sırasında alınan videolardan elde edilen çerçeveler.

Koklama hareketi için oluşturulmuş veri setinden örnekler Şekil 4.6'da gösterilmiştir.



Şekil 4.6. Köpeğin koklama hareketleri sırasında alınan videolardan elde edilen çerçeveler.

Kulak dikme hareketi için oluşturulmuş veri setinden örnekler Şekil 4.7'de gösterilmiştir.



Şekil 4.7. Köpeğin kulak dikme hareketleri sırasında alınan videolardan elde edilen çerçeveler.

Kuyruk sallama hareketi için oluşturulmuş veri setinden örnekler Şekil 4.8’de gösterilmiştir.



Şekil 4.8. Köpeğin kuyruk sallama hareketleri sırasında alınan videolardan elde edilen çerçeveler.

Oyun oynama hareketi için oluşturulmuş veri setinden örnekler Şekil 4.9’da gösterilmiştir.




Şekil 4.9. Köpeğin oyun oynama hareketleri sırasında alınan videolardan elde edilen çerçeveler.

4.4. CNN Algoritması ile Eğitim Kümesi Üzerinde İşlem Adımlarının Takip Edilmesi

CNN mimarisi kullanılarak oluşturulan katman yapısı önceki bölümlerde anlatılmıştır (Bkz. Çizelge 4.1). Bu bölümde bahsedilen katmanlarda takip edilen adımlar ve elde edilen çıktılardan bahsedilecektir.


Önerilen tez çalışmasında incelenmesine karar verilen altı farklı hareketler için video sahneleri üzerinde ilgili bölümün işaretlenmesi işlemi yapılmaktadır. Bunun için öncelikle köpeğin sergilediği hareket alanı içerisinde tanımlama yapılacak olan hareketin/davranışın olduğu bölge işaretlenmekte ve ilgili her hareket için özellikleri çıkarılarak derin öğrenme ağına sunulacak sayısal verilere dönüştürülmüştür. Bu sayısal veriler her hareket için bölgenin matematiksel karşılıklarının çıkarıldığı 4x1'lik koordinant noktalarının olduğu matris dosyasına karşılık gelmektedir. Bu amaçla köpeğin izlenecek olan altı farklı hareket için ilgili bölgelerinin belirlenmesi işlemi Şekil 4.10'da gösterilmiştir. Bu alan işaretleme işlemi, eğitim esnasında ağın tüm çerçeve üzerinden hareketi bularak öğrenmek yerine sadece ilgili hareketin bulunduğu alana odaklanarak daha hızlı ağı eğitmesini sağlamaktadır.



Şekil 4.10. Köpeğin altı farklı hareketi/davranışları için ilgili bölgenin işaretlenmesi. a) ağız açma bölgesi, b) dil çıkarma bölgesi, c) kuyruk sallama bölgesi, d) kulak dikme bölgesi, e) koklama bölgesi, f) oyun oynama bölgesi.


İşaretlenen bölgelerin koordinatları alındıktan sonra bu koordinatlar eğitim yazılımına tanıtılmaktadır. Bilgisayarın sistem özelliklerine göre eğitim süresi için belirli bir bekleme gerekmektedir.

Ağının eğitim eğitimin doğru yapıp yapılmadığını kontrol etmek için bazı aşamaların takip edilmesi gerekmektedir. Bu aşamalardan birincisi, köpeğin davranışının analiz edileceği bölgenin bulunmasıdır. Şekil 4.11’de gösterilen çerçeveler eğitim veri setinde her bir hareket için kullanılan videodan ağın aldığı ilk çerçevedir. Köpeğin altı farklı hareketi için kırmızı kutu ile çerçevelenmiş ROI bölgesinin (ilgili alanın) işaretlenmiş şekilde çıktılar elde edilmiştir. Bu aşamada eğitilen hareket için doğru alanı vermesi, hareket tanımlanması için doğru koordinant noktalarının tespit edildiğinin bir göstergesidir. Ayrıca bu işlemin yapılmasının amacı, bir resim tüm detayları ilgilenmek yerine sadece ilgili alan üzerinde çalışma yapılması hedeflenmektedir.



Şekil 4.11. Köpeğin altı farklı hareketi/davranışları için ROI bölgesinin bulunması. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi.

İkinci aşamada köpeğin davranışı analiz edilecektir. Daha önceden koordinatları belirlenen çerçevelerin eğitimi sonucunda, bu koordinatlara benzer olarak kare beyaz işaretçiler ile işaretlenerek elde edilen çıktılar Şekil 4.12’de görülmektedir. Eğitim videosunda hareketlerin tracker (izleyiciler) ile izlemesine olanak sağlayan beyaz işaretçiler, hareketlerle ilgili bölgelere işaretler bırakarak video izlenmesinin daha kolay olmasını sağlamaktadır. Bir sonraki aşamada bu ilgili alanlar eğitim videolarında izlenecektir. Bu aşama eğitilen hareket için doğru alanı taraması eğitim sürecinin doğru ilerlediğinin göstermektedir.




Şekil 4.12. Köpeğin sergilediği altı farklı hareketi/davranışları için ilgili alanın işaretlenmesi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi.

Üçüncü aşamada, eğitim veri setindeki herhangi bir video kullanılarak köpeğin ilgili davranışı gösterip göstermediği tespit edilmektedir. Köpeğin istenilen davranışına ait yeşil işaretçiler vasıtasıyla Şekil 4.13'te gösterildiği gibi video süresi boyunca trackerlar ile takip edilmiştir. Test işleminin sonucunda tüm hareketler eğitim videolarında başarılı olarak izlendiği tespit edilmiştir.



Şekil 4.13. Köpeğin altı farklı hareketlerinin/davranışlarının eğitim videoları boyunca yeşil işaretçiler (tracker) ile izlenmesi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi.

Dördüncü aşamada, eğitim veri setindeki herhangi bir video kullanılarak köpeğin ilgili davranışı gösterip göstermediği eğitim verilerinde test edilmektedir. Yapılan testler sonucunda köpek ilgili davranışı gösteriyorsa Şekil 4.14’de gösterildiği gibi sarı çerçeve ile işaretlenerek tespit edilen ilgili hareketin adı yazılacaktır. Bu işlem aslında nesne algılama (object detection) diye adlandırılan işleme karşılık gelmektedir. Bu aşama, nesne algılama işlemi ile anlık olarak köpeklerin hareketlerinin tespit edilebilmesi ile günlük hayatımızda bu sistemin hayata geçirilebilir olması açısından önemlidir.



Şekil 4.14. Pozisyonları çıkarılmış veri seti eğitime tabi tutulduktan sonra sistemin eğitilip eğitilmediğinin gösterildiği altı farklı hareketin/davranışın sarı çerçeve ile gösterimi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi.

Beşinci aşamada, veri setindeki herhangi bir video kullanılarak köpeğin ilgili davranışı gösterip göstermediği eğitim verilerinde test edilmektedir. Eğitimi yüzde kaç oranda bir başarı ile tamamladığının bulunması ve bu sonucun bir çıktısının sunulması

için bu aşamadaki algoritma kullanılmaktadır. Bu başarı oranını gösterebilmek için, yapılan hareketin olduğu bölümü kare sarı bir çerçeve ile dış ortama çıktı sunması sağlanmıştır. Yapılan deneysel çalışmalar sonucunda ağız açma, dil çıkarma, koklama, kulak dikme, kuyruk sallama, oyun oynama davranışları eğitime tabi tutulmuş ve bu davranışlar için sırasıyla %100, %99.99,%99.28, %99.99, %95.99, %99.64 sınıflandırma başarımları elde edilmiştir. Bu aşamadan sonra eğitim verileri ile değerlendirilmekte ve bu eğitim verileri kullanılarak test edilecek veriler üzerinde davranışların sınıflandırma başarı oranlarına bakılacaktır.



Şekil 4.15. Altı farklı hareket/davranışlar için, pozisyonları çıkarılmış veri seti eğitime tabi tutulduktan sonra eğitim başarı sonuçlarının gösterilmesi. a) ağız açma hareketi %100, b) dil çıkarma hareketi %99.99, c) kuyruk sallama hareketi %99.99, d) kulak dikme hareketi %95.99, e) koklama hareketi %99.28, f) oyun oynama hareketi %99.64 başarı elde edilmiştir.

4.5. Eğitilmiş Veri Seti Kullanılarak, Davranışların Analiz Edileceği Test Veri Setindeki Videolar Üzerinde Sistem Başarımlarının Test Edilmesi

Bu aşamada eğitim işleminde kullanılmayan test veri setinden yeni bir video kullanılarak köpeğin ilgili davranışı gösterip göstermediği tespit edilmektedir. Herhangi bir videoda altı farklı hareket için ilgili alan takip edilmektedir. Bu aşamadan sonra test verileri ile değerlendirilmektedir ve altı farklı hareket için sistem karşılaştırılması yapılarak eğitimin sınıflandırma başarı oranları incelenecektir. Köpeğin altı farklı hareket için eğitimi tamamlandıktan sonra test verilerindeki herhangi bir video seçilerek köpeğin yapmış olduğu hareket için video süresi boyunca hareketin izlenmesi görülmektedir.



Şekil 4.16. Köpeğin altı farklı hareket/davranış için test veri setinde ilgili hareketlerin tracker ile izlenmesi. a) ağız açma hareketi, b) dil çıkarma hareketi, c) kuyruk sallama hareketi, d) kulak dikme hareketi, e) koklama hareketi, f) oyun oynama hareketi.

4.6. Deneysel Çalışmalar

Tez kapsamında köpeğin ağız açma, dil çıkarma, kulak dikme, kuyruk sallama, koklama, oyun oynama gibi belirlenmiş altı farklı davranışının analizi ve sınıflandırılması ile ilgili deneysel çalışmalar yürütülmüştür.

Önerilen tez çalışmasında, köpek görüntülerinin sınıflandırılabilmesi için MATLAB ortamında derin öğrenme tabanlı bir uygulama yazılımı geliştirilmiştir. Çalışmada yapılan tüm uygulamalar MATLAB yazılımı ile oluşturulan uygulama üzerinde gerçekleştirilmiştir. Tüm deneysel çalışmalar 2.8 Ghz i7 işlemcili ve 16 GB belleğe sahip bir bilgisayar üzerinde yapılmıştır.

Köpekler üzerine yapılan birçok çalışmada köpeklerin doğal yaşamlarında en çok yaptıkları durma, yürüme, koşma vb. gibi temel hareketlerin sisteme öğretilmesi ve sınıflandırılması amaçlanmıştır (Kitani, vd., 2011; Nguyen vd., 2015; Ehsani, vd., 2018; Gerencser, vd., 2013; Ladha, vd., 2013). Önerilen tez çalışmasının diğer çalışmalardan farkı, ağız açma, dil çıkarma, koklama, kuyruk sallama, kulak dikme ve oyun oynama olarak altı hareket üzerinde durulmasıdır. Bu hareketler köpeklerin bir duygu karşısında verdikleri tepkileri göstermektedir. Örneğin, bir mama gösterdiğinizde onu ağzını açarak beklemesi, bir korku veya şüpheli durum olması karşısında kulaklarını dikmesi, öğretilmiş bir kokuyu (arama köpeklerinde olduğu gibi) çevresinde hissettiğinde oraya doğru yönelmesi gibi durumlara çözüm bulunması ve yaklaşım getirilmesi düşünülerek bu hareketler üzerinde tez çalışması sürdürülmüştür.

Tüm videolar elde edildikten sonra, altı farklı hareket düşünülerek video veri setinin tamamı izlenmiştir ve videolarda tespit edilen bu hareketlerin olduğu bölümler video kırpma uygulamaları kullanarak kırpılmıştır. Kırpılan videolar minimum 3 saniye ile maksimum 8saniye arasındadır. Bu sürelerin kısa olmasının iki ana sebebi vardır. Bunlardan birinci, eğitim süresini hızlı ve etkili yapmak içindir. İkincisi ise çıkarılan video parçacıklarının her hareketten sadece birine odaklanmış olduğu anları yakalamaktır. Bu odaklanmış hareketlerin seçilmesi sınıflandırma aşamasında bir video parçacığında olan iki veya daha fazla hareket için çakışmayı önleyecektir ve ayrıca eğitimin daha yüksek oranlarda başarılı olmasını sağlayacaktır. Kırpılan video veri seti her hareket için daha özelleştirilmiş bir içeriğe sahip olması sağlanmıştır. Her bir hareketi içeren video veri setinin %70'i eğitim için ayrılırken %30'u ise test verisi olarak kullanılmıştır. Daha sonra her hareketin video parçacığından çerçeve çıkarma

uygulamaları ile altı hareketin çerçeveleri çıkarılmıştır. Tanımlanan CNN modeli kullanılarak her bir hareket için sistemin eğitimi yapılmıştır. Bu modelde hareketler için yüksek başarı oranları yakaladığımız için değiştirme gereksinimi duyulmamıştır. Fakat eğer davranışların tanınmasında başarı oranları istenilen ölçüde olmaması halinde modelde değişikliğe gidilmesi gerekmektedir. Eğitim işlemleri adım adım takip edilerek yapılmaktadır. Eğitim aşaması tamamlandıktan sonra, eğitim ve test videolarında hareketlerin tracker ile takip edilmesi durumunda eğitim aşaması tamamlanmaktadır. Bu aşamadan sonra, her hareket için test veri setinden on adet çerçeve seçilmektedir. Eğitilmiş her bir hareket, test veri setinden seçilmiş diğer her on adet test veri seti ile kıyaslanmaktadır. Bu kıyaslanma sonuçları sistemin sınıflandırma başarısının elde edilmesini sağlamaktadır. Elde edilen her bir başarılı veya hatalı eşleşmeler yorumlanarak ilgili hareket için veri seti değiştirilmiş veya eğitim tekrarlanmıştır. Tüm bu çalışmaların çıktıları sunulmuştur.

4.6.1. Ağız açma

Ağız açma hareketi için sistemin eğitilmesi yapılmıştır. Eğitim yapıldıktan sonra ilgili hareket için herhangi 10 farklı çerçeve alınmıştır. Ağız açma hareketleri kendi içerisinde karşılaştırmalar yapılarak Çizelge 4.2'de gösterilen başarı oranları elde edilmiştir. Yapılan eğitimin sınıflandırma başarı oranları da ayrıca tespit etmek için, ağız açma çerçeveleri diğer beş hareket ile kıyaslamaya alınmıştır. Bu kıyaslamanın amacı ise sistem eğitimin çapraz olarak test edilmesi hedeflenmiştir. Örneğin: kulak dikme çerçeveleri için ağız açma hareketi kıyaslanmasında hiçbir alanı taramaması işaretçi koymamasını beklenmektedir. Fakat köpeklerin saniyeler içerisinde yüz ifadelerinde ki değişiklikler sistemin farklı hareketleri de yakalamasına olanak vermektedir. Bu nedenle kulak dikme hareketi çerçeveleri içerisinde anlık olarak ağız açma hareketi gerçekleştirdiyse köpek sistem bu hareketi yakalacaktır ve ağız açma hareketi için eşleşme olacaktır. Her bir hareket için test veri setinden alınan on çerçeve için Çizelge 4.2'de gösterilen sonuçlar elde edilmiştir. Eğitim başarısıbeş hareket ile sınıflandırıldığında %100 oranında bir sonuç alınmıştır. Yani sıfır eşleşme %100 başarı anlamına gelmektedir.

Çizelge 4.2. Ağız açma hareketi sınıflandırma sonuçları

Test Edilen Davranış	Sınıflandırma Karşılaştırması Yapılan Hareket/Davranış					
	Ağız Açma	Dil Çıkarm a	Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynam a
1	%78.49	%0	%0	%0	%0	%0
2	%100	%0	%0	%0	%0	%0
3	%99.99	%0	%0	%0	%0	%0
4	%100	%0	%0	%0	%0	%0
5	%100	%0	%0	%0	%0	%0
6	%99.89	%0	%0	%0	%0	%0
7	%52.12	%0	%0	%0	%0	%0
8	%99.98	%0	%0	%0	%0	%0
9	%100	%0	%0	%0	%0	%0
10	%99.99	%0	%0	%0	%0	%0

Hem Çizelge 4.2'den hem de eşleşmelerin olduğu Şekil 4.17 ve 4.18'den bazı hareketlerde, tanımlanmış diğer beş hareket için herhangi bir eşleşme olmamıştır. Şekil 4.17 ve 4.18'in ilk satırında test veri setindeki her bir hareket için başarılı örnekleri içermektedir. Örneğin, ağız açma hareketi diğer beş hareket ile kıyasladığımız da sadece ağız açma hareketi için sarı işaretçi ile çerçevelenmiş 'ağız açma' ifadesi olması beklenir. Diğer beş hareketin test verileri için işaretlenmiş herhangi 'ağız açma' hareketi tespit edilmemesi başarılı eşleşme anlamına gelmektedir. Bu sonuç ağız açma hareketinin diğer beş hareket için sınıflandırma sonuçlarının %100 olduğu anlamına gelmektedir.

Şekil 4.17 ve 4.18'in ikinci satırında ifade edilen hatalı kıyaslama eşleşmeleri ise, ağız açma hareketinin eğitiminden sonra ağız açma verisi ile her bir hareket için seçilen on adet test verisinin kıyaslanma sonuçlarını içermektedir. Şöyle ki, eğitimi tamamlanmış ağız açma hareketini on adet ağız açma test verisi ile kıyaslandığında sarı işaretçi ile çerçevelenmiş 'ağız açma' ifadesi olmaması durumunda bu sonuç başarısız eşleşme olarak ifade edilmektedir. Diğer beş hareketin veri setinde sarı işaretçi ile çerçevelenmiş 'ağız açma' rastlanması durumu başarısız eşleşme olacaktır. Şekil 4.17 ve 4.18'de ifade edilen 'hatalı eşleşme yok' ibaresi on test verisi için %100 başarı sağlandığı anlamına gelmektedir. Örneğin, kuyruk sallama test veri setinde sarı işaretçi ile çerçevelenmiş 'ağız açma' hareketi yakalaması durumu başarısızlık olarak ifade edilmektedir ve 'ağız açma' eşleşmesi olan hareket için örnek çerçeve Şekil 4.18'de

gösterilmiştir. Diğer tüm hareketlerin sınıflandırma tabloları bu durum göz önüne alınarak hazırlanmıştır.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Ağız Açma	Ağız Açma	Dil Çıkarma	Koklama
			
	Hatalı Kıyaslama		
Ağız Açma	Ağız Açma	Dil Çıkarma	Koklama
	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.17. Köpeğin ağız açma hareketi sınıflandırma sonuçları için örnek çerçeveler.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Ağız Açma	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
			
	Hatalı Kıyaslama		
Ağız Açma	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.18. Köpeğin ağız açma hareketi sınıflandırma sonuçları için örnek çerçeveler.

4.6.2. Dil çıkarma

Dil çıkarma hareketi için sistemin eğitilmesi yapılmıştır. Eğitim yapıldıktan sonra her bir hareket için test veri setindeki herhangi on farklı çerçeve alınmıştır. Dil çıkarma hareketi her bir hareket için sınıflandırma karşılaştırması yapılarak Çizelge 4.3'te gösterilen başarımlar elde edilmiştir. Eğitimi yapılmış dil çıkarma çerçeveleri diğer altı hareket için oluşturulan on adet test verisi ile karşılaştırılmıştır. Test veri setinden seçilen dil çıkarma çerçevelerinin tamamında eğitimi yapılan dil çıkarma verileriyle eşleşme olmuştur ve başarımlar oranı %100'dür.

Çizelge 4.3. Dil çıkarma hareketi sınıflandırma sonuçları

Test Edilen Davranış	Sınıflandırma Karşılaştırması Yapılan Hareket/Davranış					
Dil Çıkarma	Ağız Açma	Dil Çıkarma	Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
1	%0	%78.49	%0	%0	%0	%0
2	%0	%100	%0	%0	%0	%0
3	%0	%99.99	%0	%0	%0	%0
4	%0	%100	%0	%0	%0	%0
5	%0	%100	%0	%0	%0	%0
6	%0	%99.89	%0	%0	%51.1	%0
7	%0	%52.12	%0	%0	%0	%0
8	%0	%99.98	%0	%0	%0	%0
9	%0	%100	%0	%0	%0	%0
10	%0	%99.99	%0	%0	%0	%0

Çizelge 4.3'te dil çıkarma yedinci test verisinde başarı oranının %52.12 oranında kalmasının nedeni, yedinci çerçevede dil çıkarma hareketinin ağız içine geldiği ana karşılık gelmesinden kaynaklanmaktadır. Bu nedenle hareket tam olarak izlenemediği için başarı oranı düşük çıkmıştır. Sınıflandırma işlemlerinde gözlemlenen bir durum ise, ağız açma hareketi çerçevelerinin karşılaştırılmasında gerçekleşmiştir. Ağız açma hareketi için seçilen on adet test veri setindeki çerçeveler ile dil çıkarma çerçeveleri sınıflandırıldığında sarı işaretçi ile çerçevelenmiş '*dil çıkarma*' imgesi gözlemlenmiştir. Şekil 4.19'da bu eşleşme için bir örnek sunulmuştur. Bunun nedeni ise ağız açma hareketi sergileyen köpeğin video açısı düşünüldüğünde bu hareketin dil çıkarma hareketi olarak algılanabilmektedir. Bu durumun doğruluğunun sağlanması için test veri

setinden farklı on adet ağız açma çerçevesi alınmıştır ve sınıflandırma bu yenilenen çerçeveler için tekrarlanmıştır. Elde edilen sonuçlar Şekil 4.19'deki gibi %100 olarak elde edilmiştir. Diğer kuyruk sallama hareketi için sınıflandırma sonuçlarında, kuyruk sallama altıncı test verisinde köpeğin dil çıkardığı hareketi yakalamış ve eşleşme gerçekleşmiştir. Şekil 4.20'de örnek çerçeve eşleşmesi sunulmuştur.

Çizelge 4.3'te belirtilen başarı ve başarısızlık olarak değerlendirilen eşleşmeler ile ilgili olarak, Şekil 4.19 ve 4.20'de örnekler gösterilmektedir.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Dil Çıkarma	Ağız Açma	Dil Çıkarma	Koklama
			
	Hatalı Kıyaslama		
Dil Çıkarma	Ağız Açma	Dil Çıkarma	Koklama
		Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.19. Köpeğin dil çıkarma hareketi sınıflandırma sonuçları için örnek çerçeveler.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Dil Çıkarma	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
			
	Hatalı Kıyaslama		
Dil Çıkarma	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
	Hatalı Eşleşme Yok		Hatalı Eşleşme Yok

Şekil 4.20. Köpeğin dil çıkarma hareketi sınıflandırma sonuçları için örnek çerçeveler.

4.6.3. Koklama

Koklama hareketi için sistemin eğitilmesi yapıldıktan sonra her bir ilgili hareket için test veri setinden on farklı çerçeve alınmıştır. Koklama hareketi hem kendi davranış grubu içerisinde hem de diğer beş farklı hareket grubundaki çerçeveler ile karşılaştırması yapılarak Çizelge 4.4'te gösterilen başarımlar elde edilmiştir. Koklama hareketi için eşleşme sonuçları ortalama %100 başarı ile bulunmuştur. Çizelge 4.4'te görüleceği gibi, yedinci ve dokuzuncu ağız açma çerçevelerinde ve bir tane altıncı kuyruk sallama test verisinde sarı işaretçi ile çerçevelenmiş 'koklama' eşleşmesi olmuştur. Bu eşleşmeler incelendiğinde köpeğin farklı bölgelerinde 'koklama' hareketi tespit etmiştir. Bu hatalı eşleşmeler için Şekil 4.21 ve Şekil 4.22'de örnekler gösterilmiştir. Diğer dil çıkarma ve oyun oynama test verilerinde herhangi bir 'koklama' hareketi tespit edilmemiş ve %100 başarı oranı elde edilmiştir.

Çizelge 4.4. Koklama hareketi sınıflandırma sonuçları

Test Edilen Davranış	Sınıflandırma Karşılaştırması Yapılan Hareket/Davranış					
	Ağız Açma	Dil Çıkarma	Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
1	%0	%0	%100	%0	%0	%0
2	%0	%0	%100	%0	%0	%0
3	%0	%0	%100	%0	%0	%0
4	%0	%0	%99.99	%0	%0	%0
5	%0	%0	%100	%0	%0	%0
6	%0	%0	%100	%0	%55.1	%0
7	%53.48	%0	%100	%0	%0	%0
8	%0	%0	%99.99	%0	%0	%0
9	%81.44	%0	%99.99	%0	%0	%0
10	%0	%0	%99.99	%0	%0	%0

Koklama sınıflandırmasında karşılaşılan bu problemten dolayı, koklama eğitim seti güncelleştirilerek çerçeve sayısı artırılmıştır. Ağ artırılmış çerçeve sayısı ile yeniden eğitildi ve ağız açma çerçevelerinin de eşleşmeler sıfıra indirilmiş ve %100 başarı

elde edilmiştir. Bu durum, çerçeve sayısının arttırılması, ağıın tekrar eğitilmesinin sınıflandırma başarı parametrelerini etkilediğini göstermektedir.Şekil 4.21 ve Şekil 4.22’de sınıflandırma yapıldığında karşılaşılan hatalı eşleşmeler ile ilgili örnekler gösterilmiştir.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Koklama	Ağız Açma	Dil Çıkarma	Koklama
			
	Hatalı Kıyaslama		
Koklama	Ağız Açma	Dil Çıkarma	Koklama
		Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.21. Köpeğin koklama hareketi sınıflandırma sonuçları için örnek çerçeveler.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
			
	Hatalı Kıyaslama		
Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
	Hatalı Eşleşme Yok		Hatalı Eşleşme Yok

Şekil 4.22. Köpeğin koklama hareketi sınıflandırma sonuçları için örnek çerçeveler.

4.6.4. Kulak dikme

Kulak dikme hareketi için sistem eğitilmesi yapıldıktan sonra ilgili her hareket için test veri setinden herhangi on farklı çerçeve alınmıştır. Eğitim veri setinde kullanılan kulak dikme çerçeveleri, oluşturulan diğer test kulak dikme çerçeveleri ile diğer beş hareket için oluşturulan test verileri karşılaştırması yapılmıştır. Çizelge 4.5'te gösterilen başarımlar elde edilmiştir. Kulak dikme hareketi ve diğer beş hareket %100 başarı ile doğru sonuçlanmıştır.

Çizelge 4.5. Kulak dikme hareketi sınıflandırma sonuçları

Test Edilen Davranış	Sınıflandırma Karşılaştırması Yapılan Hareket/Davranış					
	Ağız Açma	Dil Çıkarma	Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
1	%0	%0	%0	%99,99	%0	%0
2	%0	%0	%0	%100	%0	%0
3	%0	%0	%0	%100	%0	%0
4	%0	%0	%0	%100	%0	%0
5	%0	%0	%0	%100	%0	%0
6	%0	%0	%0	%100	%0	%0
7	%0	%0	%0	%100	%0	%0
8	%0	%0	%0	%100	%0	%0
9	%0	%0	%0	%100	%0	%0
10	%0	%0	%0	%100	%0	%0

Şekil 4.23 ve Şekil 4.24'te kulak dikme hareketi ile ilgili sınıflandırılma sonucunda elde edilen örnekler gösterilmektedir. Altı hareketler için yapılan sınıflandırma işleminde hatalı eşleşme olmamış ve başarı %100 gerçekleşmiştir.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Kulak Dikme	Ağız Açma	Dil Çıkarma	Koklama
			
	Hatalı Kıyaslama		
Kulak Dikme	Ağız Açma	Dil Çıkarma	Koklama
	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.23. Köpeğin kulak dikme hareketi sınıflandırma sonuçları için örnek çerçeveler.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Kulak Dikme	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
			
	Hatalı Kıyaslama		
Kulak Dikme	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.24. Köpeğin kulak dikme hareketi sınıflandırma sonuçları için örnek çerçeveler.

4.6.5. Kuyruk sallama

Kuyruk sallama hareketi için sistemin eğitilmesi yapılmıştır. Daha sonra her hareket için herhangi 10 farklı çerçeve seçilmiştir. Kuyruk sallama çerçeveleri sırasıyla tüm hareketler için test veri setinden seçilen çerçeveler ile karşılaştırılmıştır. Elde edilen sonuçlara göre bu hareketlerin kendi içerisinde karşılaştırması yapılarak Çizelge 4.6'da başarımları elde edilmiştir. Eğitimi tamamlanan dil çıkarma çerçeveleri altı hareket için seçilen on adet veri seti ile karşılaştırılmıştır. Kuyruk sallama hareketi test çerçeveleri ile karşılatırıldığında başarı oranı %100 çıkmamıştır. Kuyruk sallama üçüncü test çerçevesinde Şekil 4.26'daki gibi kuyruk hareketi arkada ve görülmediği için tanımlama olmamıştır. Diğer tüm hareketler ile hiçbir çakışma olmadan sınıflandırmada %100 başarıya sahip olmuştur.

Kuyruk sallama davranışı çok hareketli olduğundan dolayı elde edilen veri setinde çok farklı yapıda kuyruk boyutuna, pozisyonuna ve şekline sahip çerçevelerden oluşmaktadır. Bu hareketlilik nedeniyle videolardan alınan çerçevelerin de bozulma olasılığı çok yüksektir. Bu problemin üstesinden gelmek için, alınan çerçevelere ek olarak sentetik veri üretilerek ağın eğitilmesi gerçekleştirilmiştir. Sabit çerçevelerden ağın eğitilmesi işleminde ağın tam olarak eğitilmediği gözlemlenmiştir. Çoğaltılmış çerçeve içeriğine sahip ağ daha yüksek başarı oranlarına sahip olmuştur.

Çizelge 4.6. Kuyruk sallama hareketi sınıflandırma sonuçları

Test Edilen Davranış	Sınıflandırma Karşılaştırması Yapılan Hareket/Davranış					
	Ağız Açma	Dil Çıkarma	Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
1	%0	%0	%0	%0	%78.49	%0
2	%0	%0	%0	%0	%78.47	%0
3	%0	%0	%0	%0	%0	%0
4	%0	%0	%0	%0	%99.49	%0
5	%0	%0	%0	%0	%99.49	%0
6	%0	%0	%0	%0	%99.53	%0
7	%0	%0	%0	%0	%99.49	%0
8	%0	%0	%0	%0	%99.49	%0
9	%0	%0	%0	%0	%80.74	%0
10	%0	%0	%0	%0	%99.99	%0

Şekil 4.25 ve Şekil 4.26’da kuyruk sallama hareketi ile ilgili sınıflandırılma sonucunda elde edilen örnekler gösterilmektedir. İlgili hareket için tüm hareketlerinin sınıflandırma başarısı %100 olarak gerçekleşmiştir.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Kuyruk Sallama	Ağız Açma	Dil Çıkarma	Koklama
			
	Hatalı Kıyaslama		
Kuyruk Sallama	Ağız Açma	Dil Çıkarma	Koklama
	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.25. Köpeğin kuyruk sallama sınıflandırma sonuçları için örnek çerçeveler.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Kuyruk Sallama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
			
	Hatalı Kıyaslama		
Kuyruk Sallama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
	Hatalı Eşleşme Yok		Hatalı Eşleşme Yok

Şekil 4.26. Köpeğin kuyruk sallama sınıflandırma sonuçları için örnek çerçeveler.

4.6.6. Oyun oynama

Oyun oynama hareketi için sistemin eğitilmesi yapıldıktan sonra, her hareket için test veri setinden herhangi 10 farklı çerçeve seçilmiştir. Oyun oynama çerçeveleri diğer tüm çerçeveler ile sırasıyla kıyaslanmıştır. Bu kıyaslama Çizelge 4.7’de gösterilen neticesinde başarımlar elde edilmiştir. Oyun oynama çerçevelerinden tamamında eşleşme olmuştur ve bu %100 başarı demektir. Sadece kuyruk sallama hareketinin sınıflandırılmasında dokuzuncu ve onuncu çerçevelerde sarı işaretçi ile çerçevelenmiş ‘*oyun oynama*’ eşleşmesi elde edilmiştir. Kuyruk sallama hareketinde Şekil 4.28’de gösterildiği gibi köpeğin tamamını işaretlemiştir.

Çizelge 4.7. Oyun oynama hareketi sınıflandırma sonuçları

Test Edilen Davranış	Sınıflandırma Karşılaştırması Yapılan Hareket/Davranış					
Oyun Oynama	Ağız Açma	Dil Çıkarma	Koklama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
1	%0	%0	%0	%0	%0	%99.81
2	%0	%0	%0	%0	%0	%99.99
3	%0	%0	%0	%0	%0	%75.95
4	%0	%0	%0	%0	%0	%99.99
5	%0	%0	%0	%0	%0	%99.27
6	%0	%0	%0	%0	%0	%99.99
7	%0	%0	%0	%0	%0	%99.87
8	%0	%0	%0	%0	%0	%99.98
9	%0	%0	%0	%0	%99.26	%99.99
10	%0	%0	%0	%0	%97.65	%99.99

Şekil 4.27 ve Şekil 4.28 'de kuyruk sallama hareketinde problemlili olan eşleşme için örnek bir çerçeve gösterilmiştir.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Oyun Oynama	Ağız Açma	Dil Çıkarma	Koklama
			
	Hatalı Kıyaslama		
Oyun Oynama	Ağız Açma	Dil Çıkarma	Koklama
	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok	Hatalı Eşleşme Yok

Şekil 4.27. Köpeğin oyun oynama sınıflandırma sonuçları için örnek çerçeveler.

TEST EDİLEN DAVRANIŞ	SINIFLANDIRMA KARŞILAŞTIRMASI		
	Başarılı Kıyaslama		
Oyun Oynama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
			
	Hatalı Kıyaslama		
Oyun Oynama	Kulak Dikme	Kuyruk Sallama	Oyun Oynama
	Hatalı Eşleşme Yok		Hatalı Eşleşme Yok

Şekil 4.28. Köpeğin oyun oynama sınıflandırma sonuçları için örnek çerçeveler.

5. TARTIŞMA VE SONUÇLAR

Önerilen tez çalışmasında, köpeklerin davranışlarının analiz edilmesi ve sınıflandırılması amacıyla literatür taraması, araç-gereçlerin temini, verilerin toplanması, video verilerinden çerçeveler elde edilmesi, çerçeveler üzerinden özellik çıkarımı işlemleri, ağız eğitilmesi, davranışların sınıflandırılması ve köpeğin eş zamanlı takip edilmesi aşamalarında oluşan bütüncül bir sistem önerilmiştir. Tüm aşamalar birbirinden hem ayrılmaz bir bütün iken hem de çok farklı prosedürlerden oluşmaktadır.

Köpeklere giydirilen ve sahibi tarafından manuel olarak kullanılabilen kameralar sayesinde köpeklerin doğal ortamlarında yaşarken belli aralıklarla videolar alınarak veri setleri oluşturulmuştur. Elde edilen videolardan altı farklı hareketlerin (ağız açma, dil çıkarma, koklama, kulak dikme, kuyruk sallama, oyun oynama) bulunduğu video parçaları çıkarılmıştır. Bu videoları kesmek için video kırpma uygulamaları kullanılmıştır. Bu video parçacıkları en kısa 3 saniye en uzun 8 saniye olacak şekilde kısaltılmıştır. Bu saniye aralıklarındaki farklılık köpeklerin bu hareketleri yaparken hızlarından kaynaklanmaktadır. Videolardan anlamlı bölümlerin çıkarılmasından sonra görüntü çerçeveleri elde edilmiştir. Toplam hareketler için yaklaşık 1020 saniyelik 160 adet video ve bu videolardan elde edilmiş her bir hareket için 3000 civarında çerçevenin olduğu veri setleri oluşturulmuştur. Bu veri setinin 2100 adedi eğitim veri seti olarak 900 adedi ise test veri seti olarak kullanılmıştır.

Yapılan deneysel çalışmalarda köpeklerin ağız açma, dil çıkarma, koklama, kulak dikme, kuyruk sallama, oyun oynama davranışları incelenmiş ve bu davranışlar için sırasıyla %100, %99.99, %99.28, %99.99, %95.99, %99.64 eğitim başarımları elde edilmiştir. Veri seti hazırlıklarının ardından video parçacıkları ile resim çerçeveleri kullanılarak bir dizi tanıma ve sınıflandırma işlem adımları gerçekleştirilmiştir. Eğitim setinin haricinde oluşturulan test video veri seti üzerinden köpeğin hangi davranışı sergilediğinin kıyaslanması yapılmıştır. Yapılan sınıflandırma kıyaslama sonuçları detaylı çizelgeler ve sekiler ile verilmiştir. Sınıflandırma yapılırken karşılaşılan problemlere çözümler bulunmuş ve sınıflandırma başarı oranları yükseltilmiştir. Bu sorunlardan bazıları, oluşturulan veri setlerindeki çerçevelerin iki veya üç farklı hareketi birden içeriyor olmasıdır. Örneğin, ağız açma hareketi için oluşturulan bir veri setinin çerçeveleri hem kuyruk sallama hareketi hemde dil çıkarma hareketini içeriyor olması kıyaslama yaparken yanlış eşlemelere sebep olmaktadır. Bu yanlışlığı gidermek için

çerçevelerin çıkartıldığı video parçacıkları çok kısa sürelerde tutulmuştur. Kısa tutulmasının sebebi ise, köpek tarafından yapılan hareket tam sergilenmiş olmasını ve başka hareketler içermemesi eğitim ve sınıflandırma başarısını arttırması için en önemli detaylardan biridir.

Davranışların eğitilmesi ve sınıflandırması için oluşturulan derin sinirsel ağın eğitim başarısını etkileyen en önemli faktörlerden biri oluşturulan modelden kaynaklanmaktadır. Konvolüsyon katmanındaki filtrelerin varlığı bu modellerin başarısının temelini oluşturmaktadır. Derin ağların en önemli özelliklerinden biride sonsuz sayıda ağ modelleri oluşturmaya olanak sağlamasıdır. Bu parametrelerden katman sayısı, konvolüsyon katmanı, filtre boyutu, tipi ve sayısı, havuzlama katmanı filtre boyutu model oluşturmak için çeşitlilik sağlayan değişkenleri içermektedir.

Önerilen tez çalışmasından sonra yapılacak olan tez çalışmalarına ışık tutması açısından, derin öğrenme işlemlerinde çok fazla veri seti olması gerektiği için veri seti hazırlarken ve istenilen anlamlı bölümler elde edilirken elinizdeki veri sayısı içerik açısından yetersiz olabileceğinden önerilen ağların eğitimi için ön-eğitilmiş ağlar kullanılabilir. Önerilen tez çalışmasında CIFAR -10 veri seti kütüphanesi kullanılmıştır. Elde edilen video süreleri ve adetleri göz önüne alındığında, 5 dakikalık bir videodan alınacak çerçeve sayısı ile ortalama 5 saniyeye düşürülmüş video parçacığından alacağınız çerçeve arasında büyük bir fark vardır. Bu durumda veri setini geniş tutup çeşitlendirmek ağ eğitimi esnasında çok önemli olacaktır. Ağın eğitimi sırasında resimlerin çözünürlüklerinin iyi olmasının ne kadar önemli olduğu ağın başarı oranlarında elde edilen farklılıklardan önerilen tez çalışmasında anlaşılmıştır. Ayrıca derinsel sinirsel ağlarda işlem adımlarının daha hızlı gerçekleşmesi için, bilgisayarınızın donanımsal olarak güçlü olması gerekmektedir. Ancak GPU'ya ihtiyacınız olup olmadığı çalışacağınız veri setine, modelinizin karmaşıklığına ve zaman kısıtınıza bağlı olarak değişkenlik gösterecektir.

Bu çalışmada elde edilen başarı oranının yüksek olması ileride yapılacak olan diğer hayvan türleri üzerinde yapılacak çalışmalara ve altı farklı hareketin dışında davranışlarının belirlenmesi çalışmalarına altyapı oluşturacaktır. Daha sonraki çalışmalarda farklı sınıflandırma algoritmalar ile derin öğrenme sınıflandırma algoritmalarının birbirine entegre edilmiş hali ile eğitim başarı oranı arttırılabileceği düşünülmektedir. Başarı oranını etkileyen diğer faktörler ise veri setinde kullanılan

videoların artırılmasıdır. Önerilen tez çalışmasında veri setindeki herhangi bir video parçacığı üzerinde sadece tek bir hareket izlenecek şekilde tasarlanmıştır. Bir sonraki tez çalışmalarında, köpeğin sergilediği birden fazla hareketi izlemek olacaktır. Ayrıca önerilen tez çalışmasında genel anlamda vücut hareketleri üzerine yoğunlaşıldığı için köpeklerin yüz hareketleri üzerinde durulmadı. Bir sonraki tez çalışmalarında, köpeğin vücut hareketleri ve yüz mimikleri aynı anda değerlendirilerek köpeğin duygusu ortaya çıkarılabilir.

KAYNAKLAR

- Acil Tıp Uzmanları Derneği, (<http://www.atuder.org.tr/>), (Erişim Tarihi: 21.05.2018).
- Adams, J., U., “Genetics of Dog Breeding”, *Nature Education*,1(1):144 (2008).
- Aenishaenslin, C., Brunet P., Lévesque, F., Gouin, G., G., “Understanding the Connections Between Dogs, Health and Inuit Through a Mixed-Methods Study”, *EcoHealth*, doi.org/10.1007/s10393-018-1386-6, (2018).
- Aggarwal, J., Ryoo, M. S., “Human activity analysis: A review”, *ACM Computing Surveys*, 10.1145/1922649.1922653, USA (2011).
- Aktuel Arkeoloji (<http://www.aktuelarkeoloji.com.tr/>), (Erişim Tarihi: 10.12.2018).
- American Society for the Prevention of Cruelty to Animals, (<https://www.asPCA.org/>), (Erişim Tarihi: 13.12.2018).
- Bagherinezhad, K., Redmon, H., J., Mottaghi, R., Farhadi, A., “Who Let The Dogs Out? Modeling Dog Behavior From Visual Data”, *IEEE Conference on Computer Vision and Pattern Recognition*, (2018).
- Bipati, (<http://bipati.co/>), (Erişim Tarihi: 21.05.2018).
- Björnerfeldt, S., Webster, M., T., Vilà, C., “Relaxation of selective constraint on dog mitochondrial DNA following domestication”, *Genome Research* 16, doi:10.1101/gr.5117706, (2006).
- Brugarolas, R., Loftin, R. T., Yang, P., Roberts, D.L., Sherman, B., Bozkurt A., “Behavior recognition based on machine learning algorithms for a wireless canine machine interface”, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 10.1109/EMBC.2012.6346964, USA (2012).
- Byosiére, S., E., Chouinar, P., A., Howell, T., J., Bennett, P., C., “What do dogs (*Canis familiaris*) see? A review of vision in dogs and implications for cognition research”, *Psychonomic Bulletin & Review*, Volume 25, Issue 5, pp 1798–1813 (2018).
- Cho, Y., Yunyoung, Y., J., Choi, N., Cho, W., “SmartBuckle: human activity recognition using a 3-axis accelerometer and a wearable camera”, *Proceedings of the 2nd International Workshop on Systems and Networking Support for Health Care and Assisted Living Environments*, 978-1-60558-199-6 (2008).
- Ehsani, K., Bagherinezhad, H., Redmon, J., Mottaghi, R., Farhadi, A., “Who Let The Dogs Out? Modeling Dog Behavior From Visual Data”, *CVPR-2018*, San Francisco, 1803.10827v2 (2018).
- Ellegren, H., “Genomics: The dog has its day”, *Nature* 438, 745–746, doi:10.1038/438745a (2005).

KAYNAKLAR (Devam Ediyor)

- Ergün, E., Gürkan, F., Kaplan, O., Günsel, B., “Derinlikli Öğrenme ile Video Aktivite Sınıflandırma”, **2017 IEEE**, 978-1-5090-6494-6/17/\$31.00, (2017).
- Farhadi, F. A., Rehg, J. M. “Understanding egocentric activities”, International Conference on Computer Vision,10.1109/ICCV.2011.6126269, Spain, (2011).
- Fly Dog Turkey, (<https://www.flydogturkey.com/>), (Erişim Tarihi: 21.05.2018).
- Doggie Drawings, (<https://www.doggiedrawings.net/>), (Erişim Tarihi: 15.12.2018).
- Gerencsér, L., Vásárhelyi, G., Nagy, M., Vicsek, T., Miklósi, A., “Identification of behaviour in freely moving dogs (*Canis familiaris*) using inertial sensors”, **PLOS ONE**, 10.1371 (2013).
- Girshick, R., Donahue, J., Darrell, T., Malik, J., "Rich feature hierarchies for accurate object detection and semantic segmentation", **IEEE Conference on Computer Vision and Pattern Recognition (Cvpr (V5))**,CVPR.2014.81 (2014).
- Girshick, R., “Fast r-cnn”, **IEEE International Conference on Computer Vision (ICCV)**,10.1109/ICCV.2015.169 (2015).
- Hammerla, N., Y., Halloran, S., Plötz T., “Deep, Convolutional, and Recurrent Models for Human Activity Recognition Using Wearables”, **“IJCAI’16 Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence”**, 1533-1540, London, UK (2016).
- Hare, B., Tomasello, M.,“Human-like social skills in dogs?”, **Trends in Cognitive Sciences** 9, 439–444 (2005).
- Hillspet, (<https://www.hillspet.com.tr/>), (Erişim Tarihi: 15.12.2018).
- Iwashita, Y., Takamine, A., Kurazume, R., Ryoo, M.S., “First-person animal activity recognition from egocentric videos”, **22nd International Conference on Pattern Recognition (ICPR)**, 10.1109/ICPR.2014.739, Sweden (2014).
- Ji, S., Xu, W., Yang, M., Y. Kai, “3D Convolutional Neural Networks for Human Action Recognition”, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 10.1109/TPAMI.2012.59 (2013).
- Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., Fei-Fei, L., “Large-scale Video Classification with Convolutional Neural Networks”, **IEEE Conference on Computer Vision and Pattern Recognition**, 10.1109/CVPR.2014.223, USA (2014).
- Kitani, K. M., Okabe, T. , Sato, Y., Sugimoto, A. “Fast unsupervised ego-action learning for first-person sports videos”, **IEEE Conference on Computer Vision and Pattern Recognition**, 10.1109/CVPR.2011.5995406, USA (2011).

KAYNAKLAR (Devam Ediyor)

- Kitani, K. M., Ziebart, B. D., Bagnell, J. A., Hebert, M., “Activity Forecasting”, *The 12th European Conference on Computer Vision*, Berlin, (2012).
- Ko, K., Ko, H., Park, S. “Convolutional Feature Vectors and Support Vector Machine for Animal Sound Classification”, *IEEE Engineering in Medicine and Biology Society. Conference* , 2018:376-379, (2018).
- Koppula, H. S., Saxena, A., “Anticipating Human Activities using Object Affordances for Reactive Robotic Response”, *IEEE Transactions on Pattern Analysis and Machine Intelligence* , 10.1109/TPAMI.2015.2430335, (2015).
- Kurt, F., “Evrışimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi”, Yüksek Lisans Tezi, *Hacettepe Üniversitesi Fen Bilimleri Enstitüsü*, ANKARA (2018).
- Ladha, C., Hammerla, N., Hughs, E., Olivier, P., Plotz, T. “Dog’s Life: Wearable Activity Recognition for Dogs”, *ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 10.1145/2493432.2493519, Switzerland, (2013).
- Lan, T., Chen, T., C., Savarese, S., “A Hierarchical Representation for Future Action Prediction”, *ECCV 2014*, Part III, LNCS 8691, pp. 689–704, Switzerland ,(2014).
- Leos-Barajas, V., Photopoulou, T., Langrock, R., Patterson, T. A., Watanabe, Y., Murgatroyd, M., Papastamatiou, Y. P. “Analysis of animal accelerometer data using hidden Markov models”, *British Ecological Society*, (2016).
- Liu, Y. H., “Feature Extraction and Image Recognition with Convolutional Neural Networks”, *Journal of Physics Conference Series*, China 1087(6):062032, (2018).
- Lu, Z., Grauman, K., “Story-Driven Summarization for Egocentric Video”, *IEEE Conference on Computer Vision and Pattern Recognition*, 10.1109/CVPR.2013.350, USA, (2013).
- Molnar, C., Kaplan F., Roy P., Pachet F., Pongracz P. Doka A., Miklosi A., “Animal Cognition” “Classification Of Dog Barks: A Machine Learning Approach”, *Animal Cognition* , (2008).
- M. Gor, J. Vora, S. Tanwar, S. Tyagi, N. Kumar, M. S. Obaidat, B. Sadoun, GATA: “GPS-Arduino based Tracking and Alarm system for protection of wildlife animals”, *International Conference on Computer, Information and Telecommunication Systems (CITS)*, 10.1109/CITS.2017.8035325, China, (2017).

KAYNAKLAR (Devam Ediyor)

- Nie, Y., Takaki, T., Ishii I., Matsuda, H., “Behavior recognition in laboratory mice using HFR video analysis”, *IEEE International Conference on Robotics and Automation*, 10.1109/ICRA.2011.5979791, China, (2011).
- Nguyen, H. G., Nans, A., Talke, K., Candela, P., Everett, H.R., “Automatic behavior sensing for a bomb-detecting dog”, *International Society for Optics and Photonics*, ADA622447, (2015).
- Ostrander, E. A., Wayne, R. K., “The canine genome”, *Genome Research* **15**, 1706–1716, doi:10.1101/gr.3736605, (2005).
- Parker, H. G., “Genetic structure of the purebred domestic dog”, *Science* **304**, 1160–1164, doi:10.1126/science.1097406, (2004).
- Pennisi, E., “Where did your dog come from? New tree of breeds may hold the answer”, *Evolution, Plants & Animals*, 10.1126/science.aal1098, (2017).
- Peterson, J., C., Soulos, P., Nematzadeh, A., Griffiths T.L., “Learning Hierarchical Visual Representations in Deep Neural Networks Using Hierarchical Linguistic Labels”, *40th Annual Conference of the Cognitive Science Society*, USA, 2018.
- Pirsiavash, H., Ramanan, D., “Detecting activities of daily living in first-person camera views”, *IEEE Conference on Computer Vision and Pattern Recognition*, 10.1109/CVPR.2012.6248010, USA, (2012).
- Ren, S., He, K., Girshick, R., Sun, J., “Faster R-CNN: Towards Real-Time Object Detection With Region Proposal Networks”, *IEEE Transactions on Pattern Analysis and Machine Intelligence, Volume 39 Issue 6*, TPAMI.2016.2577031, USA, (2017).
- Rodin, C., D., Lima, L., Andrade, F., Haddad, D. B., Johansen, T. A. and Stovold R., “Object Classification in Thermal Images using Convolutional Neural Networks for Search and Rescue Missions with Unmanned Aerial Systems”, *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 10.1109/IJCNN.2018.8489465, Brazil, (2018).
- Royal Canin, (<http://www.royalcanin.com.tr/>), (Erişim Tarihi: 15.12.2018).
- Sağiroğlu, Ş., Koç O., “Büyük Veri Ve Açık Veri Analitiği: Yöntemler Ve Uygulamalar”, *Gazi Üniversitesi Big Data Center*, ISBN: 978-605-9247-59-7 Ankara, 2017.
- Samuel, D., Karam, L., “A Study and Comparison of Human and Deep Learning Recognition Performance Under Visual Distortions”, *26th International Conference on Computer Communications and Networks, ICCCN*, Canada, (2017).

KAYNAKLAR (Devam Ediyor)

- Security Magazine, (<https://www.securitymagazine.com/articles/85277>), (Erişim Tarihi: 17.12.2018).
- Scott, J., P., Fuller, J., L., “Genetics and the Social Behaviour of the Dog”, *University of Chicago Press*, (1974).
- Sichkar V., “Convolutional Neural Networks for Image Classification with CIFAR-10 dataset”, (2018).
- Stanford University, CS231n: Convolutional Neural Networks for Visual Recognition, <http://cs231n.github.io/linear-classify/#softmax>., (Erişim Tarihi: 08.12.2018).
- T. N. Y. Times, (<https://www.nytimes.com/2011/05/12/world/middleeast/12dog.html>) (Erişim Tarihi:10.12.2018).
- Trnovszky, T., Kamencay, P., Orjeseck, R., Benco, M., Sykora, P., “Animal Recognition System Based on Convolutional Neural Network”, *Advances In Electrical And Electronic Engineering*, 10.15598/aeec.v15i3.2202, (2017).
- Ulrich, S., Ruo, H., Yang, C., “Analyzing animal behavior via classifying each video frame using convolutional neural networks”, *Scientific Reports*, 14351, (2015).
- Wright J.C., Nesselroth, M. S., “Classification Of Behavior Problems In Dogs: Distributions Of Age, Breed, Sex And Reproductive Status”, *Applied Animal Behaviour Science*, 19(1-2): 169-178, (1987).
- Yılmaz, O., Ertuğrul, M., “Türkiye Yerli Köpek Irk ve Tipleri”, *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 2(1):99-106, (2012).

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı :Rukiye POLATTİMUR
Doğum Yeri/ Tarihi :TOKAT/06.05.1989



Eğitim Durumu

Lisans Öğrenimi :Süleyman Demirel Üniversitesi Elektronik ve Haberleşme Mühendisliği (2007-2012)

İş Denevimi

Çalıştığı Kurumlar :Litpa Aydınlatma(2014-2016)
:Heper Moonlight Aydınlatma(2013-2014)
:Alfamax Yapı ve Donanımları LTD.STİ.(2012-2013)

İletişim:

Adres :BİLECİK/MERKEZ
E-posta :rukiyeozubek@gmail.com

Yayınlar

"Endüstriyel Tesisler İçin Led'li Yüksek Tavan Armatürü" isimli bildiri yayınının hazırlanması ve sunulması

http://www.emo.org.tr/etkinlikler/aysem/etkinlik_bildirileri_detay.php?etkinlikkod=249&bilkod=6168

"RF Haberleşme Sistemi ile LED'li Yol Aydınlatması Uygulaması" isimli proje sunumunun VIII. ULUSAL AYDINLATMA SEMPOZYUMU BİLDİRİLERİ'nde gerçekleştirilmesi

"PCA- Based Animal Classification System" isimli makalenin 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies isimli sempozyumda ingilizce olarak sunulması

Projeler

TÜBİTAK BİDEP 2209 nolu proje kapsamında "Farklı Tekniklerin Kombinasyonları İle İnsan Aktivitesi Tanıma"konu başlığında proje destek bursu aldım ve 1 yıllık çalışma sonucunda projeyi tamamladım, Sdü-Müh.Mimarlık Fakültesi Elektronik Ve Haberleşme Mühendisliği Bölümü, 2013

1511-Enerji-2013-Ev-13 Çağrısı M1 Ve M2 Aydınlatma Sınıfı Yollar İçin Led'li Armatür Geliştirilmesi Projesi kapsamında Elektronik ve Haberleşme Mühendisi olarak görev aldım, 2014

TÜBİTAK destekli bir proje olan "Biodinamik Aydınlatma Sistemleri" isimli projede Elektronik Sorumlusu olarak görev aldım, 2015-2016

BAP destekli"Bilgisayarlı Görü Temelli Hayvan Davranışı Analizi Ve Sınıflandırılması" isimli projede yüksek lisans öğrenci olarak görüntü ve video işleme, rapor hazırlanması işlemlerinin gerçekleştirilmesi işlemlerinde görev aldım, 2017-2018

Yabancı Diller: İELTS 5.5 / YDS:62.5

Ales :84.68

Tarih:07/01/2019