



**DERİN ÖĞRENME TEMELLİ İÇ MEKAN
YÖNLENDİRME UYGULAMASI**

Ebru SOMUNCU

**2022
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Nesrin AYDIN ATASOY**

**DERİN ÖĞRENME TEMELLİ İÇ MEKAN YÖNLENDİRME
UYGULAMASI**

Ebru SOMUNCU

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

**Tez Danışmanı
Dr. Öğr. Üyesi Nesrin AYDIN ATASOY**

**KARABÜK
Ocak 2022**

Ebru SOMUNCU tarafından hazırlanan “DERİN ÖĞRENME TEMELLİ İÇ MEKAN YÖNLENDİRME UYGULAMASI” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY
Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 05/01/2022

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Danışmanı : Dr. Öğr. Üyesi Nesrin AYDIN ATASOY (KBÜ)
Üye : Dr. Öğr. Üyesi Ferhat ATASOY (KBÜ)
Üye : Dr. Öğr. Üyesi Abdullah ELEN (BANÜ)ONLINE.....

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

Prof. Dr. Hasan SOLMAZ
Lisansüstü Eğitim Enstitüsü Müdürü

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

Ebru SOMUNCU

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TEMELLİ İÇ MEKAN YÖNLENDİRME UYGULAMASI

Ebru SOMUNCU

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY

Ocak 2022, 46 sayfa

Son yıllarda artan nüfus ile birlikte insanların hastane, alışveriş merkezi gibi yaşam alanlarında harcadıkları zaman da artmaktadır. Açık alanlarda yaşanan sıkıntılara ek olarak kapalı alanlarda da ulaşım konusunda insanların istedikleri yerlere ulaşmak için harcadıkları zaman binaların karmaşıklığına bağlı olarak değişmektedir. Bu noktada iç mekanlarda insanların yönlendirilmesi için farklı yaklaşımlar araştırma konusu olmuştur. Derin öğrenme temelli yönlendirme çalışmalarına katkı olarak bu tez çalışmasında yönlendirme işlemleri iki adımda ele alınmaktadır. İlk olarak mağaza konum bilgisinin alınması için Transfer öğrenmeye dayalı Evrişimsel Sinir Ağları (CNN) mimarisi kullanılmıştır. Oluşturulan model mimarisi mağaza görüntülerinden yönlendirme için başlangıç bilgisini vermektedir. Bir sonraki adımda yönlendirme adımları Android mobil uygulama aracılığıyla kullanıcıya sunulmaktadır. Uygulama ile kullanıcıların internet bağlantısı olmadan aynı ve farklı katlar arasında yönlendirme işlemi gerçekleştirilmektedir.

Anahtar Sözcükler : İç mekan yönlendirme, derin öğrenme, CNN, transfer öğrenme, dijkstra algoritması.

Bilim Kodu : 92431

ABSTRACT

M. Sc. Thesis

DEEP LEARNING BASED INDOOR ROUTING APPLICATION

Ebru SOMUNCU

Karabük University

Institute of Graduate Programs

Department of Computer Engineering

Thesis Advisor:

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY

January 2022, 46 pages

With the increasing population in recent years, the time people spend in living spaces such as hospitals and shopping centers is also increasing. In addition to the difficulties experienced in open areas, the time people spend in transportation in indoor areas to reach the places they want varies depending on the complexity of the buildings. At this point, different approaches to directing people indoors have been the subject of research. In this thesis, as a contribution to deep learning-based routing studies, routing processes are discussed in two steps. Firstly, Convolutional Neural Networks (CNN) architecture based on Transfer learning was used to retrieve store location information. The model architecture created gives the initial information for routing from the store images. In the next step, the routing steps are presented to the user via the Android mobile application. With the application, users can be routed between the same and different lines without an internet connection.

Key Word : Indoor navigation, deep learning, CNN, transfer learning, dijkstra algorithm.

Science Code : 92431

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öğr. Üyesi Nesrin AYDIN ATASOY'a sonsuz teşekkürlerimi sunarım.

Sevgili aileme manevi hiçbir yardımı esirgemedен yanımda oldukları için tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	2
İÇ MEKAN YÖNLENDİRME.....	2
2.1. LİTERATÜR ÇALIŞMASI	3
BÖLÜM 3	8
DERİN ÖĞRENME.....	8
3.1. DERİN ÖĞRENME MİMARİLERİ.....	11
3.1.1. Evrişimsel Sinir Ağları (CNN).....	11
3.1.2. Transfer Öğrenme	16
3.1.2.1. MobileNetV2	19
BÖLÜM 4	22
SINIFLANDIRMA MODELİNİN TASARIMI VE İÇ MEKAN YÖNLENDİRME PROBLEMİNE UYGULANMASI	22
4.1. VERİ SETİ	23
4.1.1. Veri Setinin Hazırlanması.....	24

	<u>Sayfa</u>
4.2. MOBİLENETV2 İLE MAĞAZA GÖRÜNTÜLERİNİN SINIFLANDIRILMASI	25
4.3. SINIFLANDIRMA MODELİNİN ANDROİD İLE KULLANIMI	28
4.3.1. Dijkstra Algoritması ile Yönlendirme	29
BÖLÜM 5	34
DENEYSEL ÇALIŞMALAR.....	34
5.1. SINIFLANDIRMA MODELİ SONUÇLARI	34
5.2. MOBİL UYGULAMA SONUÇLARI.....	36
BÖLÜM 6	39
SONUÇLAR	39
KAYNAKLAR	40
ÖZGEÇMİŞ	46

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1. Evrişimsel sinir ağlarının genel katman yapısı.	12
Şekil 3.2. Evrişimli sinir ağı yapısı	12
Şekil 3.3. Evrişim yapısı.....	13
Şekil 3.4. Aktivasyon fonksiyonları.	14
Şekil 3.5. Havuzlama işlemi.....	15
Şekil 3.6. (a) Evrişimli sinir ağı yapısı. (b) Bırakma uygulanmış sinir ağı yapısı ...	15
Şekil 3.7. Tam bağlantılı katman yapısı.	16
Şekil 3.8. Transfer öğrenme çalışma prensibi.	18
Şekil 3.9. Derinlemesine ayrılabilir konvolüsyon.	20
Şekil 4.1. Uygulama iş akış diyagramı.....	23
Şekil 4.2. Eğitim için örnek veriler.	24
Şekil 4.3. CNN mimarisinin ayrıntılı yapısı.....	26
Şekil 4.4. Sınıflandırma için MobileNetV2 mimarisi.	26
Şekil 4.5. MobileNetV2 darboğaz katmanı.	26
Şekil 4.6. Tasarlanan modele genel bakış.	27
Şekil 4.7. Model yapısı..	28
Şekil 4.8. Modelin .tflite dönüşümü.	29
Şekil 4.9. Örnek graf modeli.	30
Şekil 4.10. Buyaka alışveriş merkezi örnek kat planı.	31
Şekil 4.11. Sözde kod.	32
Şekil 4.12. Kat planına ait json dosya bloğu.	33
Şekil 4.13. Canvas ile kat planı üzerinde yönlendirme.	33
Şekil 5.1. Modelin başarımlı değeri.....	35
Şekil 5.2. Modelin kayıp değeri.	35
Şekil 5.3. Aynı kat üzerinde yönlendirme.	37
Şekil 5.4. Farklı kat üzerinde yönlendirme.	37

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 3.1. MobileNetV2 katman yapısı.....	20
Çizelge 4.1. Eğitilmiş MobileNetV2 model mimarisi.	28
Çizelge 4.2. Noktalar arası en kısa yol mesafe bilgileri.....	31
Çizelge 5.1. Modelin tasarlandığı ortam özellikleri.....	34
Çizelge 5.2. Çapraz doğrulama başarımları.....	36
Çizelge 5.3. Redmi 8A teknik özellikleri.....	36

KISALTMALAR DİZİNİ

KISALTMALAR

- BLSTM : Bidirectional Long Short Term Memory (İki Yönlü Uzun Kısa Süreli Bellek)
- CNN : Convolutional Neural Network (Evrışimsel Sinir Ağları)
- DC : Depthwise Convolution (Derinlemesine Konvolüsyon)
- DWC : Depthwise Separable Convolution (Derinlemesine Ayrılabilir Konvolüsyon)
- PWC : Pointwise Convolution (Noktasal Konvolüsyon)
- GPS : Global Positioning System (Küresel Konum Belirleme Sistemi)
- LSTM : Long Short Term Memory (Uzun Kısa Süreli Bellek)
- NLP : Natural Language Processing (Doğal Dil İşleme)
- RFID : Radio Frequency Identification (Radyo Frekansı ile Tanımlama)
- RNN : Recurrent Neural Network (Tekrarlayan Sinir Ağları)
- WSN : Wireless Sensor Network (Kablosuz Sensör Ağı)

BÖLÜM 1

GİRİŞ

Nüfusun artması ile insanların üniversite, hastane, alışveriş merkezi gibi binalarda harcadıkları zamanlarda artmaktadır. Bu binaların karmaşıklığı, belirli bir hedefe ulaşmak isteyen kişileri navigasyon uygulaması arayışına yönlendirmektedir. İç ve dış mekanlarda gerçekleştirilen modelleme ile farklı navigasyon uygulamaları tasarlanmıştır. Akıllı telefonların kullanımının artması ile bir yerden başka bir yere gitmek artık daha da kolaylaşmıştır. Dış mekanlarda uydu teknolojisine dayalı konum belirleme çalışmaları mevcuttur ancak iç mekanlarda sinyallerin aktarımından kaynaklanan sıkıntılar meydana gelmektedir. Alternatif olarak sunulan donanım destekli çalışmalar ekstra maliyet ve zaman almaktadır. Bu anlamda konum belirlemek için derin öğrenme temelli çalışmalarda araştırma konusu olmuştur.

Bu çalışmada, konum bilgisinin derin öğrenme ile tespiti ve kullanıcının en kısa rota bilgisi ile iç mekanda yönlendirmesini sağlayan mobil tabanlı bir uygulama gerçekleştirilmektedir. İç mekanlarda konum bilgisinin alınması için transfer öğrenmeye dayalı evrişimsel sinir ağı mimarisi kullanılmıştır. Bu mimarinin, Android ortama entegrasyonu ile kullanıcının bulunduğu ortamdaki mağazanın adı tespit edilir. İlk olarak sınıflandırma modeli ile kullanıcının bulunduğu kattaki mağaza görüntüsü alınır ve başlangıç noktası olarak mağaza konum bilgisi elde edilir. Daha sonra, kullanıcı hedef mağaza bilgisini mobil uygulama üzerinden seçerek rotayı oluşturur. Başlangıç ve hedef mağaza bilgilerinin kat planı üzerindeki konumlarına göre Dijkstra algoritması kullanılarak en kısa yol bilgisi oluşturulur ve bina kat planı üzerinde güzergah bilgisi kullanıcıya sunulur ve iç mekan yönlendirme gerçekleştirilmektedir.

BÖLÜM 2

İÇ MEKAN YÖNLENDİRME

Dünya üzerinde artan nüfus, kentsel yapıların artmasına ve giderek karmaşıklaşmasına neden olmuştur. Nüfus değişimine bağlı olarak bu alanlarda yaşayan insanların hayatlarını kolaylaştırmak için yönlendirme sistemleri sık kullanılır duruma gelmiştir. Dünya etrafında dönen uydular aracılığıyla nesnelerin konumunu belirleyen yönlendirme sisteminin kullanılması ile GPS teknolojisi hayatımıza girmiş ve yaygın kullanım alanı edinmiştir. Harita yapımı, jeoloji, navigasyon, arama kurtarma, hedef izleme, savunma sanayi gibi birçok uygulamada GPS'in etkin şekilde kullanıldığı görülmektedir [1].

Uydular ve mobil araçlarla dış alanların haritalanması ve detaylı bilgilerin elde edilmesi mümkündür. GPS kullanan navigasyon sistemleri günlük hayatımızda birçok noktada adres tarifi yapmaktadır. Artan kullanım alanlarına rağmen, günümüzde GPS'in dış alanlardaki yönlendirme başarısına yaklaşan bir kapalı alan yönlendirme sistemi bulunmamaktadır. Artan ve giderek karmaşık hale gelen hastane, alışveriş merkezi, kamu hizmeti sağlayan binalarda yönlendirme için yaşanan sıkıntılar düşünüldüğünde, kapalı alanlar için ortaya çıkabilecek yöntemler hayatımızı olumlu yönde etkileyecektir [2].

Kapalı alanlar için oluşturulan yönlendirme sistemleri genel alanda kullanılabilirlik sağlamadığı için, GPS sistemlerinin başarısını yakalayamamıştır. Kapalı alanlardaki yönlendirme çalışmaları bina yapılarından kaynaklı olarak, GPS'den farklı sistemlere ihtiyaç duymaktadır. Kapalı alanlar için standart bir sistem olmamasına rağmen yaklaşımlar mevcuttur.

Günümüzde yazılımdan bağımsız olarak, yol bulma problemlerine çözüm niteliğinde bina yapılarına ait kat planlarını gösteren haritalar kullanılmaktadır. Bu çözüm hastane, alışveriş merkezleri gibi yapılarda gidilen yolu kısaltmak için kullanılsa da

haritanın oluşturulmasındaki zaman kaybı ve taşınabilirliğin olmaması gibi nedenlerden kaynaklı olarak genel anlamda etkili olamamıştır ve çeşitli yazılım destekli sistemler geliştirilmiştir.

2.1. LİTERATÜR ÇALIŞMASI

Literatür çalışmalarında kapalı alanlarda yönlendirme sistemleri ile birlikte konumlandırma işleminin de ele alındığını görmekteyiz. Konum bilgisi elde etmek için çeşitli donanımsal yöntemler kullanılsa da maliyet ve hız söz konusu olduğunda bu yöntemlerin henüz bir standart olmadığı görülmektedir.

Bina modeli üzerindeki önemli noktaların (merdiven, asansör vb.) baz alınması ile yapılan çalışmada daha iyi modelleme çözümleri önerilmiştir [3]. Modelleme işlemi çoğu zaman robotların yönlendirme işleminde de kullanılmıştır. Bu alanda yapılan bir çalışmada haritalama işlemi için, iki boyutlu dikdörtgen yapılar ile topolojik modelleme işleminin karşılaştırılması yapılmıştır [4]. Burada dikdörtgen şeklinde haritalama daha keskin ve doğru sonuçlar ortaya koymaktadır. Uygun modelleme işleminin yapılmasından sonra diğer bir adım da modellerin kullanıcıya sunumudur. Mobil cihazların ekran boyutları çoğu zaman modellerin görselleştirilmesinde yeterli uygunluğu sağlamamaktadır. Chittaro çalışmasında, mobil cihazların ekran boyutlarına uygun olarak modellerin nasıl daha etkin kullanılabileceği üzerine öneriler sunmaktadır [5].

Yönlendirme uygulamaları ile ilgili literatürde donanım destekli yöntemler üzerinde de çalışılmıştır. Çalışmalarda donanıma dayalı teknolojilerin küresel olarak kapalı alanlar için kullanılamadığı gösterilmiştir [6]. Bunun nedeni kapalı alanlarda uydu sinyallerinin kullanılamaması ve kapalı alanlar için mimarilerin küçük yapılardan oluşmasıdır. Kapalı alan konum belirleme yöntemlerinden biri olan RFID, kapalı mekanlarda taşıyıcıların ya da okuyucuların tam konumlarını tespit edebilmesi ile ön plana çıkmıştır. Kapalı alanlarda GPS sistemlerinin bina yapılarından kaynaklı olarak kullanılamaması bu tip sistemlere olan ilgiyi ve ihtiyacı arttırmıştır. Yapılan çalışmada RFID ile konum belirleme çalışmalarının etkin sonuçları ve araştırmaları gösterilmiştir [7]. RFID teknolojisi ile ele alınan başka bir çalışmada, yangın durumunda her bir

kullanıcıyı kendi fiziksel özelliklerine ve binanın değişen koşullarına göre bina içinde yönlendiren bir sistem sunulmaktadır. RFID sistemlerinde veriler elektronik bir veri taşıyıcı aygıt üzerinde saklanır ve bu şekilde kullanıcıların konumları takip edilmektedir. Çalışma da kullanıcıların tahliyesi için gerekli talimatlar, bir sunucu üzerinden sinir ağı tabanlı bir modül üzerinde hazırlanmakta ve kullanıcıların akıllı telefonlarına gerçek zamanlı olarak gönderilmektedir [8]. Wang ve vd. kapalı alanlarda konumlandırma için RFID teknolojisi üzerine çalışma gerçekleştirmiştir. Çalışma da kullanılan teknoloji maliyet olarak ucuz olmasına karşın, bina modelinden harita bilgisinin oluşturulması uzun bir süreçtir [9]. Görme engelli insanların kapalı alanlardaki hayatlarını kolaylaştırmak adına yapılan başka bir çalışma da, konumlarının tespit edilmesi ve yönlendirilmesi için RFID teknolojisi kullanılmıştır. Çalışma da sinyal değişikliklerine bağlı olarak, sinyalin şiddeti ve etiket arasında eşitlik tespit edilerek kişilerin konum bilgisi elde edilmiş ve yönlendirme işlemi gerçekleştirilmiştir [10].

Kapalı alanlarda konumun belirlenmesi için görüntülerin tanınması üzerine yaklaşımlar mevcuttur. Bu yaklaşımlar mekanlara ait görüntü verilerinden bilgi ve konum ilişkilendirilmesi ile yönlendirme gerçekleştirmektedir. Yönlendirme çalışmalarının hedefi, kullanıcının bir noktadan başka bir hedef noktaya güzergah bilgisi ile yönlendirilmesidir. Bu aşamada literatürde çok araştırılan “en kısa yol” algoritmaları kullanılmaktadır. Literatürde, kapalı ve açık alanlarda donanım kaynağından bağımsız olarak yapılan çalışmalarda kısa yol algoritmaları yönlendirme için sıkça tercih edilmektedir.

Bina modelini, düğümlere sahip grafik bir yapı olarak ele alan Mohri çalışmasında grafik yapı üzerinde en kısa yol bulma algoritmasının kullanımını göstermektedir [11]. Başka bir çalışmada A* en kısa yol algoritmasının başarısı, engellerin bulunduğu bir grafik haritası üzerinde değerlendirilmiştir [12].

Garcia ve vd. çalışmasında, sürücülerin trafik akışına bağlı olarak kavşak, ışık, mesafe bilgisine göre yol seçim işlemi için Dijkstra algoritmasını temel alan PEDDA (Probabilistic Extension of Dijkstra’s Algorithm) algoritması ile iki yaklaşımı değerlendirmektedir. Bu yaklaşımlar ile sürücülerin yolların uzunluk mesafelerini

bilmedikleri durumlarda olasılık dağılımları gerçekleştirmeleri ve uzunluk bilgisinin olduğu durumlarda en uygun yol bilgisinin nasıl elde edileceğine yönelik parametreler değerlendirilmektedir. Bu şekilde akıllı trafik ışık kontrolü ve daha hızlandırılmış zaman kontrolü sağlanmaktadır [13]. Chen ve vd.'de deprem yangın gibi acil durumlarda, tehlikeli bölgeden güvenli alanlara tahliye işlemi için gerçek zamanlı olarak yol ağını analiz etmektedir. Analiz işlemi kavşakların ve yolun durumu, tahliye gecikme hızları göz önüne alınarak hesaplanmıştır. Çalışmada tahliye işlemi Dijkstra algoritması ile ele alınmış, noktalar arasındaki yol mesafe bilgisi, trafik akış bilgileri, yol gecikme süreleri gibi bilgiler ayrı ayrı değerlendirilerek en kısa mesafede ve en uygun güzergah bilgisi elde edilmiştir [14]. Navigasyon sistemleri kısa yol algoritmaları ile birçok seçenek arasından en uygun ve en kısa güzergah bilgisini kullanıcı ile paylaşmaktadır. Kullanıcı yol bilgileri arasında ki alternatif güzergahları da değerlendirerek hedef yolun hem maliyet hem de uygunluğunu görebilmektedir. Ruan ve vd. Dijkstra algoritması ile bir seyahat haritası üzerinde akıllı araç navigasyon sistemi geliştirmiştir. Yolların bağlantıları, bağlantılar arasındaki mesafe değerleri, mevcut trafik durumu algoritma ile sorgulanarak başarılı sonuçlar ortaya konulmaktadır [15]. Özdemir ve vd.'de ipek yolu koridorları arasında en kısa güzergah bilgisini Dijkstra algoritması ile ele almıştır. Bir demiryolu haritası üzerindeki noktaların mesafe bilgileri, demiryolu mesafe hesaplama aracı ile hesaplanmaktadır. Çalışmada seçilen 26 nokta bir graf modelinde ele alınmış ve bu noktalar arasındaki mesafe değerleri ile maliyet hesabı yapılarak optimum sonuçlar elde edilmiştir [16]. Kemara aracılığıyla alınan görüntüler üzerinde uygun görüntü işleme teknikleri uygulanarak yol optimizasyonları gerçekleştirilmektedir. Aracı tarafından yapılan çalışmada belirlenen bölge üzerinde gezgin robotlar ile alınan görüntülerden engel tespiti yapılarak, en uygun yol bilgisine ulaşılmaktadır. Dijkstra ve A* algoritmaları ile gerçekleştirilen işlemlerde Dijkstra, farklı boyut ve konumlardaki dairesel engelleri göz önüne alarak başarılı sonuçlar ortaya koymaktadır [17].

Dijkstra algoritmasının dış mekanlardaki yönlendirme başarısı, iç mekanlarda yapılan çalışmalarda da sıkça görülmektedir. Günlük hayatımızda bir çok kolaylık sağlayan robotların, başlangıç ve hedef noktaları arasındaki en kısa yol tespitini ele alan Koca ve Doğan, çalışmalarında Dijkstra algoritmasını kullanmıştır. Çalışmada tek katlı bir yapı üzerinde gerçekleşen yol bulma işlemlerinin, farklı katlar dahil olduğunda da

gerçekleştirilebildiği gösterilmiştir. En yakın asansör ya da merdivene dayalı yaklaşımlar ile 3 boyutlu bir düzlemde, robotların tek ve 2 katlı yapılarda yönlendirme işlemi sağlanmıştır. Robotların yönlendirilmesi için işlem süresi ve optimum sonuç avantajlarından kaynaklı Dijkstra algoritması tercih edilmiştir [18]. İç mekanlarda yaya yönlendirme işlemi günümüzde oldukça fazla kullanılmaktadır. Xu ve vd.'de kullanıcıların farklı güzergah tercihlerini de değerlendirerek en kısa yol bilgisini Dijkstra algoritması ile hesaplamıştır. Mevcut yol planlama yöntemleri dışında, kişinin gideceği noktaya olan mesafe bilgisi hesaplanırken, asansör ya da merdiven tercihleri de göz önüne alınmaktadır. Belirlenen kat planı üzerinde seçilen bir noktanın komşularına olan mesafeleri değerlendirilerek, asansör ya da merdiven tercihlerine göre Dijkstra algoritması ile en kısa yol bilgisi hesaplanmaktadır [19]. Kapalı otopark sistemleri en kısa yol algoritmalarının sıkça kullanıldığı çalışmalardır. Ata ve vd. çalışmaların da araçların büyüklük bilgilere göre girişe en yakın otoparka yönlendirmesini sağlayan akıllı kapalı otopark sistemini, Dijkstra algoritması ile ele almıştır. WSN kullanılarak yapılan birçok park sistemleri mevcuttur. Ancak tüm bu yöntemlerin kendi avantajları ve sınırlamaları vardır. Akıllı kapalı otopark sisteminin amacı, müşteriye girişe en yakın otoparkı sağlamaktır. Aynı zamanda otopark sisteminde, aracın park alanında yönlendirildiği nokta, aracın büyüklüğüne göre tahsis edilmektedir. Girişte ve çıkışta bulunan, IR sensöründen gelen giriş sinyali Dijkstra algoritması ile işleme alınarak ve Proteus (Arduino Mega 2560) ile gerçekleştirilen simülasyon ile en yakın otopark noktasına aracı yönlendirme işlemi gerçekleştirilmektedir [20]. Üç boyutlu kapalı alanlar da en az riskli yolların tespiti için GPS ve donanım tabanlı bir çok yöntem ele alınmış ancak GPS'in kapalı alanlarda sinyal erişiminin zor olması, yapılan çalışmalarda kullanılan ekstra donanım ihtiyacı farklı yöntemleri göz önüne getirmiştir. Vanclooster ve vd.'inin çalışmaların da ele alınan en az riskli yol algoritması akış olarak Dijkstra algoritmasının işlem adımlarını belirtmektedir. İç mekan dahilinde olan noktaların birbiri ile komşuluk ilişkileri tek kat ve birden fazla kat için oluşturulmuştur. Bir noktanın diğer tüm noktalara olan mesafe bilgisi de, çalışmada elde edilen sonuçların başarımlarına değerine etki etmektedir. Noktalar arasındaki ilişkiye dayalı olarak bir kattan başka bir kata erişim hem Dijkstra algoritması hemde en az riskli yol algoritması ile değerlendirilerek, en kısa yol bilgisi açık ve kapalı ortamda test edilerek karşılaştırmalı olarak gösterilmiştir [21]. GPS bilgilerinin kapalı alanlardaki dezavantajları göz önüne alınarak Fadzli ve vd. ele

aldıkları çalışmada Dijkstra algoritmasını kullanarak robotlar için yol tespiti sağlamıştır. Önerilen yöntem, yol mesafe bilgisinin yanında yolun zorluğunu da ele almaktadır. Çalışmada Dijkstra algoritması ile noktalar arasındaki komşuluk ilişkilerine göre erişim imkanları değerlendirilerek ve mesafe kaybını ortadan kaldırılarak en az zorluk derecesinde ki en kısa mesafe hesaplanmaktadır [22]. Yapılan bir başka çalışmada, Xu ve vd. iki boyutlu olarak ele alınan kat planları üzerinde, en kısa güzergah bilgilerini Dijkstra algoritması kullanarak elde etmiştir. Burada kat planları üzerindeki noktalar arasında, Delaunay üçgenleme yöntemi ile mesafe bilgileri alınmıştır. Alınan mesafe bilgileri, noktalar arasındaki mesafe ilişkilerinden en kısa yol bilgisine sahip olanı kullanıcıya sunmaktadır. Dijkstra algoritmasının diğer kısa yol algoritmalarına göre daha doğru optimum sonuçlar elde ettiği gösterilmiştir [23].

Günümüzde artan kentsel yapılaşma ve daha kapsamlı binaların ortaya çıkması, acil durumlarda ortaya çıkabilecek kayıpları da artırmaktadır. Boguslawski ve vd. üç boyutlu topolojik model yaklaşımı ile güvenli rota bilgilerini alarak afetler durumunda tahliye işlemlerinin hızlı ve güvenli olarak gerçekleştirilmesini amaçlamıştır. Xml formatında alınan kat planları üzerinde, noktaların uzaklık ilişkilerine dayanarak maliyetler hesaplanmaktadır. Burada en kısa yol güzergahı Dijkstra algoritmasının avantajları göz önüne alınarak gerçekleştirilmiş ve hem en kısa hem de en güvenli yol bilgisine ulaşılmıştır [24].

Dirik ve Kocamaz çalışmasında, en kısa yol algoritmalarını mobil robotlar ile kullanarak iç mekanların tarifini ele almaktadır. Çalışmada yol planlamaları RRT (Rapidly-Exploring Random Tree) ve Dijkstra ile çözümlenerek engelleri göz önüne alan bir yol izleme uygulaması tasarlanmıştır. RRT ve Dijkstra, en kısa ve en uygun yol güzergahı bilgisini yolun uzunluğunu ve yol üzerindeki dönüş noktalarını değerlendirerek almaktadır. İki boyutlu ortamlarda yapılan test işlemlerinde her iki algoritmanın başarılı sonuçlar vererek, çevrimdışı çalışma imkanı da sağladığı görülmektedir [25].

BÖLÜM 3

DERİN ÖĞRENME

Derin Öğrenme, makinelerin insan davranışlarını algılaması ve anlamlandırmasına yönelik en popüler yaklaşımdır. Dijital veri miktarının her geçen gün artmasıyla, verilerin analiz süreçleri önem kazanmaktadır. Derin öğrenme çok yüksek miktarda veriyi işleme yeteneği ve karmaşık yapısı ile bu verileri işleyebilecek yüksek hesaplama gücüne sahip donanımlara ihtiyaç duyar.

Bir makine öğrenmesi sınıfı olan Derin Öğrenme, verilerin birden fazla özellik seviyesinin veya temsillerinin öğrenilmesine dayalı yapıdan oluşmaktadır[26]. Denetimli, yarı denetimli ve denetimsiz olarak gerçekleştirilen derin öğrenme çalışmalarında, öğrenme işleminin başarısı çalışmada kullanılan verinin büyüklüğüne bağlı olarak değişir. Verilerin birden çok katmandan geçmesi ile her bir adımda gereken bilgi öğrenilir. Verilerden elde edilen ayırt edici özellikler, katmanlı mimari ile ele alınır. Alt seviye katmanlarda elde edilen özellikler, daha az ayırt edicidir. Alt seviyedeki katmanların birleştirilmesiyle oluşan üst katmanlardaki özellikler daha fazla ayırt ediciliğe sahiptir. Katmanlı mimari şeklinde ele alınan öğrenme yöntemi geleneksel makine öğrenmesi yöntemlerinden farklıdır.

Derin öğrenme ilk olarak 2012' de büyük ölçekli görsel tanıma (ImageNet) [27] yarışmasında nesne sınıflandırma alanında başarısını ortaya koymuştur. Yüz tanıma sistemleri, sağlık sektörü, ses tanıma çalışmaları, otonom sistemler, görüntü işleme, gelecek tahmin uygulamaları, doğal dil işleme, metin ve karakter tanıma çalışmaları, savunma ve güvenlik, nesne tanıma, sınıflandırma gibi birçok alanda da derin öğrenme mimarileri kullanılmıştır [28,29,30]. Yapılan çalışmalara ve kullanılan katman sayısına bağlı olarak farklı derin öğrenme mimarileri tercih edilmektedir. Bu bölümde derin öğrenme mimarilerinin farklı çalışma alanlarındaki kullanımlarından bahsedilmiştir. İşaret dili üzerinde yapılan çalışmada, farklı derin öğrenme

mimarilerinin başarımları değerlendirilmiştir. CNN mimarisinin görüntü verileri üzerindeki başarısı göz önüne alınarak, verilerin zamansal bilgi içermesi ve zamansal boyutta değerlendirme yapabilme yeteneğinden dolayı RNN mimarisi ve zamansal verinin boyutunun büyük olmasından kaynaklı olarak LSTM mimarisinin başarımları gösterilmiştir [31]. NLP ve biyomedikal gibi birçok alanda başarılı sonuçları olan CNN mimarileri, özellikle görüntü işleme alanında en iyi sonuçları elde etmektedir.

Cireşan tarafından ele alınan çalışmada, MNIST verileri üzerindeki hata oranı %2'lere düşürülmüştür [32]. MNIST ve NORB verileri üzerine Cireşan ve arkadaşlarının başka bir çalışması da, öğrenme süresinin çok hızlı gerçekleştiği en başarılı çalışmalardan olmuştur [33].

Yüz tanıma çalışmaları kapsamında ele alınan çalışmada, düz ve ters yüz görünümleri de dahil, geniş açılardaki 200.000 görüntü verileri üzerinde yüzlerin CNN ile başarılı tespitleri gerçekleştirilmiştir [34].

NLP problemleri üzerine CNN başarımı birçok çalışmada ortaya konulmuştur. Metinlerin anlamsal ayrıştırması üzerine yapılan çalışmada, metinlerin söz dizim analizleri için anlamsal bir çözümleme sistemi ele alınır. Bu çalışmada yanlış biçimlendirilmiş metinlerin uygun duruma getirilmesi sağlanmış ve anlamsal ayrıştırmadaki başarıyı artırmak için kaynakların artırılması gerektiği ortaya konulmuştur [35].

Kelimelerin anlamsal bilgileri üzerine yapılan çalışmada, CNN mimarisi ile kelime dizilerindeki özelliklerin tespiti sağlanmış ve yüksek doğrulukta anlamsal başarı elde edilmiştir. Gerçek dünya verileri ile ele alınan çalışma web belgeleri üzerinde sıralama işlemleri için değerlendirilmiştir [36].

İleri beslemeli sinir ağlarının aksine, temel olarak sıralı bilgileri kullanan RNN mimarisi ile ele alınan çalışmada ses bilgilerinin doğrudan metine çevirilmesi sağlamıştır [37]. RNN mimarisi, CNN ile birlikte ele alındığı başka bir çalışmada, etiketlenmemiş görüntü verileri için tanımlayıcı bir model parçası olarak

kullanılmıştır. Görüntülerde nesnelerin tespitinin yanında tanımlayıcılar ile birlikte nesnelerin konum tespiti de sağlanmıştır [38].

El yazısı karakter tanıma ve görüntü sınıflandırmak için RNN ve CNN mimarisi kullanılarak yapılan başka bir çalışmada, bu mimarilerin farklı veri setleri üzerindeki kullanımlarını ve başarımlarını göstermektedir [39].

Bir RNN türü olan LSTM mimarileri, uzun süreli bağımlılıklardan kaynaklanan problemlere çözüm olarak ele alınmıştır. Konuşma ve metin işleme konularında başarılı sonuçlar ortaya koyan bu mimari, farklı lehçelere sahip veriler üzerindeki ses sınıflandırma işleminde dikkate değer bir başarı elde etmiştir [40].

LSTM ile verimobil verileri üzerinde yapılan çalışmada, kapsamlı konuşma verileri üzerinden anahtar kelime tespiti için %84.5'lik bir başarı elde edilmiştir [41]. CNN ile ele alınan LSTM tabanlı bir yaklaşım ile de ön bilgi kullanılmaksızın insan aktivitelerinin tanımlanmasında başarılı sonuçlar ortaya konulmuştur [42].

RNN mimarisi ile nota tahmin çalışmaları başarılı sonuçlar ortaya çıkarmasına rağmen dinlenebilir bir beste oluşturulması uzun vadeli öğrenme yeteneği ile LSTM mimarileri tarafından gerçekleştirilir. Yapılan çalışmada LSTM'in blues türünde müzikleri öğrenerek besteler ortaya koyabildiği gösterilmiştir [43].

Sözlüklerin etiketlenme ve analiz işleminin gerçekleştirildiği çalışmada, BLSTM'in ileri ve geri yönlü hesaplama gerektiren işlemlerde ki başarısı ortaya koyulmuştur. BLSTM ile doğal dil çalışmalarında ortaya çıkan geriye yönelik hatırlama durumundaki hata oranı azaltılmıştır [44].

Doğal dil çalışmalarında ses analizi önemli bir çalışma alanı oluşturmuştur. BLSTM tabanlı çalışmada, çevresel faktörlerden kaynaklı konuşmanın tanınmasında ortaya çıkan zorluklar göz önüne alınarak, ses izi özelliklerinin daha ayrıntılı tespiti için asimetrik BLSTM yöntemi önerilmiştir. Çalışmada farklı çevresel gürültülerdeki eksik konuşmaların doğru tespit edilmesi sağlanmıştır [45].

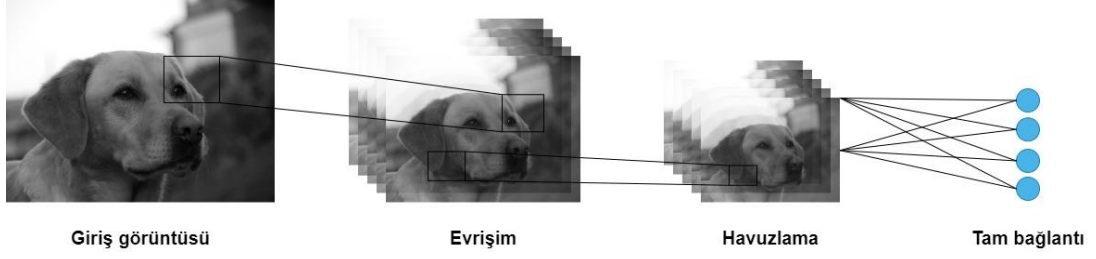
Derin öğrenme mimarileri ile ele alanın dil bilgisi tabanlı duygu analizleri, çoğu zaman tespit noktasında yanlış sonuçlar ortaya koymaktadır. Benzersiz duygu özellikleri baz alınarak yapılan çalışmalarda, model belirli uzunluk vektörleri ile ele alındığından belirli metin bilgileri kaybedilmektedir. Yapılan çalışma da öz-dikkat mekanizması ve birçok kanal özellikleri ile BLSTM mimarisi önerilmiştir. Kullanılan yöntem farklı özellikleri bir araya getirerek kelimeler arasında ilişkiye dayalı daha hassas bir duygu analiz tahminleri elde etmektedir [46].

3.1. DERİN ÖĞRENME MİMARİLERİ


Yapay sinir ağlarındaki katman sayılarının artırılması ile çok farklı türde derin öğrenme mimarileri bulunmaktadır. Bu bölümde çalışmada kullanılan CNN mimarisi ve Transfer öğrenme yaklaşımı anlatılmaktadır.

3.1.1. Evrişimsel Sinir Ağları (CNN, Convolutional Neural Network)

İleri yönlü bir sinir ağı olan CNN, hayvanların görme merkezinden esinlenilerek ortaya çıkartılmıştır. Derin öğrenme temelli bu sinir ağları, çok fazla görüntü işleme süreçlerini ve sınıflandırma adımlarını tek bir ağ yapısı ile ele alarak, görüntü sınıflandırma, nesne tespiti ve analiz çalışmalarında yoğun bir şekilde kullanılmaktadır. Klasik görüntü işlemeden farklı olarak evrişimli sinir ağlarında nesne özellikleri, oluşturulan model tarafından kendi kendine öğrenilerek gerçekleştirilir. CNN mimarisi genel olarak bir veya daha fazla evrişim katmanı, havuzlama katmanı ve bir veya daha fazla tam bağlı katmanlardan oluşmaktadır. Şekil 3.1’de evrişimsel sinir ağlarının genel katman yapısı, Şekil 3.2’de evrişimsel sinir ağı yapısı gösterilmiştir.




Şekil 3.1. Evrişimsel sinir ağlarının genel katman yapısı.



Şekil 3.2. Evrişimli sinir ağı yapısı.

Evrişimsel sinir ağları, evrişim katmanı (Convolution Layer), havuzlama katmanı (Pooling Layer), aktivasyon katmanı (Activation Layer), bırakma katmanı (Dropout Layer), tam bağlantılı katman (Full-Connected Layer) ve sınıflandırma katmanından (Classification Layer) oluşmaktadır. İlk giriş katmanında (Input Layer) giriş olarak verilen veri, boyut ve çözünürlük bilgisi bakımından tasarlanan model mimarisine uygun şekilde belirlenir. Girdi olarak ele alınan veri, sinir ağlarının önemli bir parçası olan evrişim katmanının da, filtre parametresi ile belirgin özelliklere sahip yeni girdilerin oluşturulmasını sağlar. Başarıma etki eden filtreler ile giriş verisinden matris oluşturulur. Şekil 3.3'te evrişim işlemi gösterilmiştir.



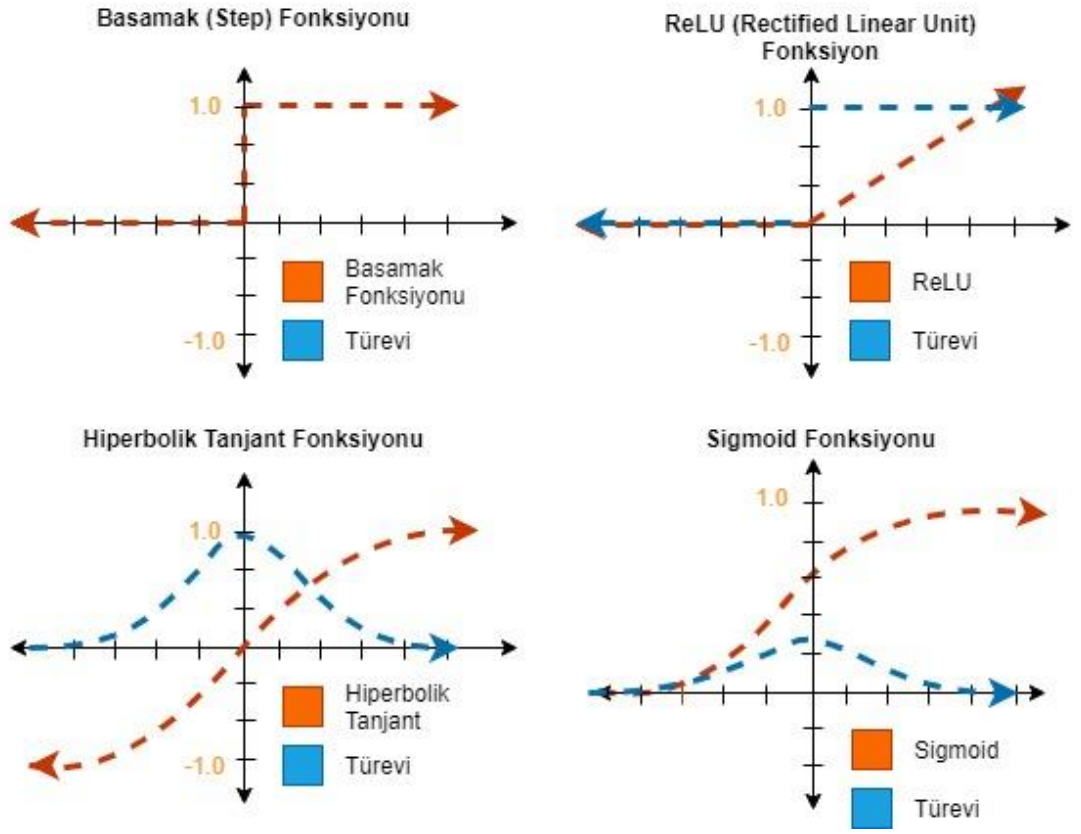
Şekil 3.3. Evrişim işlemi.

Evrişim işleminden sonra elde edilen yeni görüntünün(matris) boyutu aşağıdaki denklem ile hesaplanmaktadır [47].

$$nout = ((nin + 2p - f)s + 1) \quad (3.1)$$

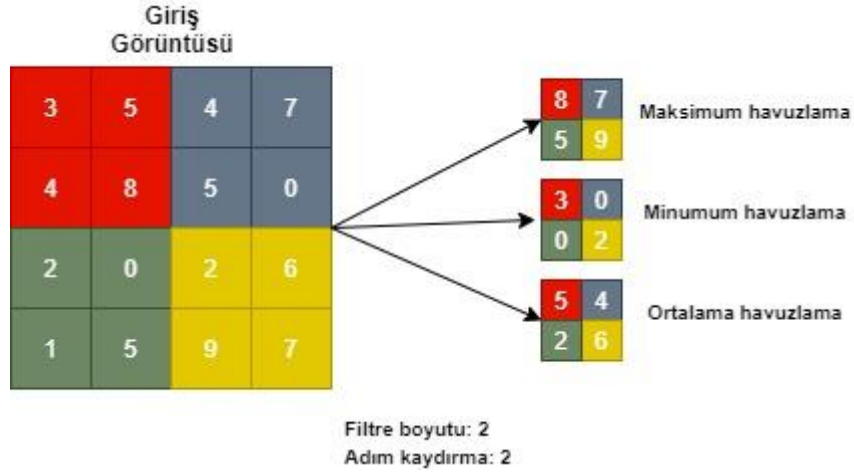
Bu denkleme göre çıkış matrisinin boyutu nout, giriş resminin boyutu nin, piksel ekleme padding(p), filtre boyutu f, adım kaydırma stride(s) bağlı olarak değişmektedir.

Filtreleme işleminin eğitim aşamasının her adımında uygulanması ile önemli bilgelerin tespiti sağlanır ve özellik haritası oluşturulur. Evrişimsel sinir ağları için yaygın kullanılan aktivasyon katmanında, aktivasyon fonksiyonu ile girdi değerlerine karşılık yeni bir çıktı matrisi elde edilerek sonraki katman için girdi değerini oluşturur. Aktivasyon fonksiyonu olarak genellikle Hiperbolik Tanjant, Basamak (Step), ReLU (Rectified Linear Unit) ve Sigmoid fonksiyonları kullanılmaktadır. Sıklıkla kullanılan aktivasyon fonksiyonlarının grafikleri Şekil 3.4'de görülmektedir.




Şekil 3.4. Aktivasyon fonksiyonları.

Evrişim işleminden sonra havuzlama katmanı ile ağıdaki parametre miktarı ve veri boyutu azaltılmaktadır. Veri boyutundaki azaltma işlemi ile sinir ağının kullandığı bellek miktarı ve hesaplama miktarı azaltılarak sinir ağının daha hızlı olması sağlanır. Veri boyutundaki azalma işleme filtreleme ile gerçekleştirilmektedir. Bu filtreleme işlemleri, en büyük değerleri (maximum pooling), en küçük değerleri (minimum pooling) veya değerlerin ortalamasını (average pooling) olarak yapılmaktadır. Şekil 3.5' de havuzlama işlemi görülmektedir.




Şekil 3.5. Havuzlama işlemi.

Bırakma katmanı derin öğrenmede en sık kullanılan tekniklerden biridir. Sinir ağında düğümleri bırakmak için belli bir olasılık değeri seçilir. Bu değer ile eğitilen model de aşırı öğrenme probleminin meydana gelmemesi için evrişimli sinir ağı katmanları arasında, rasgele düğümleri silerek aşırı öğrenme problemini ortadan kaldırmaktadır ve ağın ezber yapmasını engelleyerek performansını artırmaktadır. Şekil 3.6 (a)'da evrişimli sinir ağı yapısı, (b)'de ise bırakma katmanı uygulanmış sinir ağı yapısı görülmektedir.



Şekil 3.6. (a) Evrişimli sinir ağı yapısı. (b) Bırakma uygulanmış sinir ağı yapısı.

Uygulamalarda kullanılan veriler çok boyutludur. Son olarak ele alınan tam bağlantılı katmanda da, önceki katmandaki nöronların tamamı tek satır dizi haline getirilmektedir. Şekil 3.7'de tam bağlantılı katman yapısı gösterilmiştir.



Şekil 3.7. Tam bağlantılı katman yapısı.

Tam bağlantılı katmandan elde edilen veri sınıflandırma katmanına aktarılarak belirlenen sınıf sayısı kadar çıktı elde edilir.

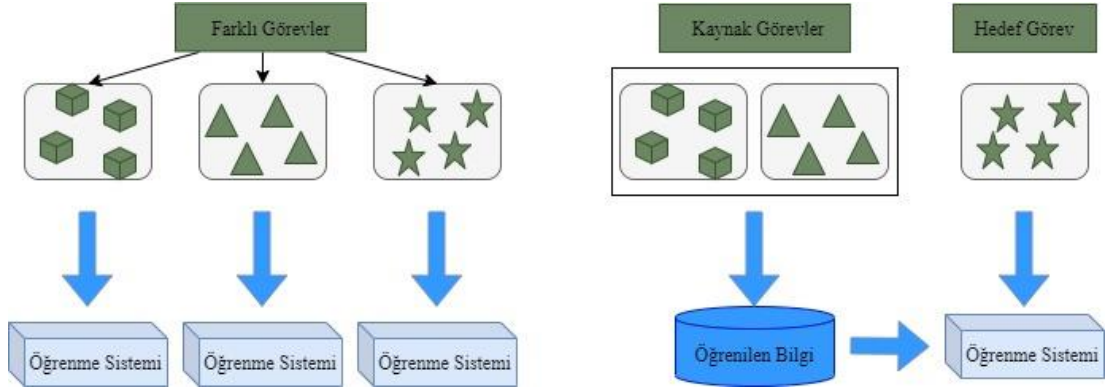
3.1.2. Transfer Öğrenme

Makine öğrenmesi yöntemleri, farklı problemleri ayrı ayrı değerlendirerek, yardımcı veri ve geçmiş bilgileri kullanmadan sıfırdan çözmeye odaklanmaktadır. Buna karşılık insanlar öğrenme süreçlerinde karşı karşıya kaldıkları problemleri geçmiş bilgi ve tecrübelerine göre değerlendirerek benzer durumlar neticesinde çözüm aramaktadır.

Makine öğrenmesi çalışmalarının temel prensibi, eğitim için belirlenen veriler ile eğitilen bir sistemin, aynı giriş ve çıkış parametrelerine sahip farklı veriler üzerinde tahminler ortaya koymasına dayanmaktadır. Ancak gerçek dünya problemlerinde gerekli eğitim verilerinin elde edilmesi ya da üretilmesi pahalı ve zaman alıcı olduğu için bu durum farklı bir yaklaşımı ortaya çıkarmaktadır. Bu yaklaşım, benzer problemler için kullanılan eğitim verilerinin gerekli düzenleme ve iyileştirmeler yapılarak aynı tür problemlerin çözümünü için kullanılmasıdır. Bu şekilde, insan öğrenim sürecindeki deneyimleme becerisinin makine öğrenmesi çalışmalarında da kullanılması sağlanmaktadır.

Güncel yöntemlerden biri olan Derin Öğrenme, başarılı sınıflandırma sonuçları ile birçok çalışmada kullanılmaktadır [26,48]. Derin öğrenme yaklaşımlarından CNN; kullanım kolaylığı, paralel çalışabilme özelliği, yüksek başarı kabiliyeti ile çok katmanlı ileri yönlü bir yapay sinir ağıdır. Sınıflandırma, nesne tanıma ve tespiti, doğal dil işleme, metin analizi gibi birçok çalışmada CNN'in başarısı ortaya konulmaktadır [49,50]. CNN ilk olarak büyük ölçekli görsel tanıma (ImageNet) [51] yarışmasında nesne sınıflandırma alanında başarısını ortaya koymuştur. Bu çalışma birçok araştırma alanı için kaynak niteliği taşımaktadır. Katmanlı yapısı ile her adımda gerekli bilgilerin öğrenilmesi ve daha az hata oranı ile sonuçların elde edilmesi CNN'in farklı çalışma alanlarında ki kullanımını da artırmaktadır. Çalışmalarda oluşturulan modellerin öğrenme başarısı ağırlık eğitimi için kullanılan verinin büyüklüğüne göre değişmektedir. CNN kullanılan çalışmalarda sıklıkla yaşanan sorunlardan biri probleme özgün eğitim verilerinin teminidir. Yüksek katman yapısı ile CNN'in genel ve özel öznitelikleri başarılı şekilde öğrenebilmesi için probleme özgü nicel ve nitel olarak yeterli eğitim verilerinin oluşturulması gerekmektedir. Örnek olarak ele alınan ImageNet veri kümesi, bir milyon imgenin kategorilenmesi ile oluşturulmuştur ve CNN kullanarak yüksek başarımlı sınıflandırma yapabilmektedir. Problemlere özgü yeterli etiketlenmiş veri bulmak zordur, bu sorunun çözümü noktasında literatürde "transfer öğrenme" olarak bilinen bilgi transferi yaklaşımı ele alınmaktadır. Bu yaklaşım, eğitim başarısı ispatlanmış veri kümesi ile eğitilen CNN ağından bilginin transferinin gerçekleştirilmesini ifade etmektedir. Transfer öğrenme yaklaşımı, insanın daha önce karşılaşmadığı problemlerin çözümü için tecrübe ettiği problemlerin çözümlerini kullanmasına dayanmaktadır [52,53]. Turizm alanında kullanılan fotoğrafların bölgelere ait kültürel ve geleneksel unsurları yansıtmada ki yetersizliğini ele alan çalışmada, görsel içeriklerin belirlenmesinde ve turistler tarafından yayınlanan fotoğrafların analiz edilmesinde transfer öğrenmeye dayalı yaklaşım kullanılmış ve başarılı sonuçlar elde edilmiştir [54]. Arama kurtarma görevlerinde, regresyon modeli ile kurtarıcının yürüme hızı tahmini ve transfer öğrenmeye dayalı model ile kayıp kişiye ait yürüme hız tahmini gerçekleştirilmiştir. Model aranan kişinin bulunabileceği maksimum alan bilgisini tahmin etmek için her yöne yürüme simülasyonunda kullanılmak da ve başarılı sonuçlar ortaya koymaktadır [55].

Bu ve benzer durumlarda problemler arasında bilginin ve verinin transferini sağlayan bu yaklaşıma “transfer öğrenme” adı verilmektedir. Transfer öğrenme ile daha önce kaynak görevler için eğitilen modellerden elde edilen özellik ve ağırlıklar yeni görevler için kullanılmaktadır. Şekil 3.8’de transfer öğrenme yaklaşımı için çalışma prensibi gösterilmiştir.



Şekil 3.8. Transfer öğrenme çalışma prensibi.

Transfer öğrenme sürecinde hangi bilginin ne zaman ve nasıl aktarılacağı büyük bir önem kazanmaktadır. En önemli aşamalardan biri olan aktarılacak bilginin doğru seçimi, hedef problem için başarı kriterini oluşturmaktadır. Çünkü bazı bilgiler kaynak problem verilerine özgü olabildiği gibi bazı bilgilerde kullanılan alandan bağımsız olarak ortak olabilmektedir. Verilerden alınan bilgilerin doğruluğu kadar, bu verilerin hangi durumlarda aktarılacağı ve nasıl aktarılacağı da çalışma sonuçları için oldukça önemlidir. Problemlere özgü olarak kaynak olarak değerlendirilen veriler ile hedef çalışmalar için belirlenen veriler farklı olabilmektedir. Bu durumda ele alınan çalışmanın eğitim başarısı da düşmektedir. Bilginin aktarımı noktasında kullanılan yöntemlerde de doğrudan aktarma ya da değiştirme yaklaşımı izlenmektedir. Bu işlemler gerçekleştirilecek çalışma için uygun olarak seçilmektedir.

Çalışmada transfer öğrenmeye dayalı bir yaklaşım kullanılmaktadır. Bu yaklaşımın tercih sebebi, daha az veri ve daha iyi performans ile daha hızlı eğitim gerçekleştirilmesidir. Eğitilen modellerin ağırlıkları birçok bilgiyi barındırmaktadır ve bu bilgiler ince ayarlamalar ile yeni modellerin hızlı eğitimini gerçekleştirmektedir. Bu şekilde kısa adımlarda daha yüksek başarımlar elde edilmektedir. Modelin eğitimi sırasında en önemli husus olan veri boyutu da transfer öğrenme ile daha az

veriden daha yüksek performanslı sonuçların alınmasını sağlamaktadır. Bu şekilde model üzerinde yapılan düzenleme ile daha performansı yüksek çalışmalar ortaya çıkmaktadır.

3.1.2.1. MobileNetV2

Derin öğrenmenin giderek popülerleşmesinin önemli nedenleri arasında donanım ve yazılım bazlı gelişmeler yer almaktadır [56]. Donanım noktasında yüksek boyutlarda verilerin hızlı işlenmesini sağlayan işlemci birimleri için alternatifler ortaya çıkmaktadır. Bu şekilde birçok derin öğrenme uygulaması mobil cihazlar üzerinde de kullanılabilir duruma gelmektedir. Güvenlik için yüz ve parmak izi tanıyan yazılımlar, ses analiz yazılımları ve arama robotlarındaki kriterlere göre reklamları belirleyen yazılımlar bunlara örnek olarak verilmektedir. Bütün bu gelişmelerin yanında veri boyutlarının ve eğitim parametrelerinin artması, ele alınan problemlerin giderek karmaşıklaşması modellerinde karmaşıklaşmasına sebep olmaktadır. Bu amaçla mobil cihazlar üzerinde derin öğrenme mimarilerinin kullanımı için daha az eğitim parametresine sahip, daha hızlı sonuçlar ortaya koyan mimariler araştırma konusu olmuştur.

MobileNet [57] mimarisi, düşük veri işleme yeteneğine sahip mobil ve gömülü sistemler üzerinde derin öğrenme uygulamaları geliştirmeyi amaçlamaktadır. Bu mimari konvolüsyonel filtreler ile görüntülerden özellik çıkarımı için standart işlemler yerine sekiz veya dokuz kat daha az parametre ile özellik çıkarımı sağlayan derinlemesine ayrılabilir konvolüsyon tekniğini kullanmaktadır.


MobileNetV2 mimarisi, mobil cihazlarda görüntüleri sınıflandırmak için kullanılabilen en önemli CNN tabanlı derin öğrenme mimarilerindedir. Mimarinin temel avantajlarından biri standart CNN modeline göre daha az parametre ve hesaplama işleminin olmasıdır [58]. Bu şekilde mobil cihazlarda çalışmaya uygun bir modeldir. Bir diğer avantajı ise görüntüdeki nesnelere ayrıntılarını ve gecikme sürelerini kontrol edebilmesidir. Bu avantajlar derin öğrenme mimarilerinin sahip olduğu konvolüsyon yapıları ile sağlanmaktadır. Bu yapılar; derinlemesine konvolüsyon(DC), derinlemesine ayrılabilir konvolüsyon(DWC), noktasal

konvolüsyon(PWC) dur. MobileNetV2 mimarisi derinlemesine ayrılabilir konvolüsyon yöntemini kullanmaktadır. Eşitlik 3.1’de standart konvolüsyon işleminde, bir sinir ağına konvolüsyon katmanı uygulandığında hesaplanan parametre değerleri gösterilmiştir.

Konvolüsyon katmanı ile parametre değerlerinin hesaplanması:

$$Girişgenişliği \times Girişyükseklği \times Filtre genişliği \times Filtreyükseklği \quad (3.2)$$

DC ile birden fazla kanala sahip giriş görüntüleri üzerinde her bir giriş kanalına ayrı ayrı filtre uygulanarak bir çıkış matrisi elde edilmektedir. DWC de bu durumlara ek olarak kanallar arasında farklı çıkış kanalları için 1×1 boyutunda standart konvolüsyon işlemi gerçekleştirilmektedir. Şekil 3.9’da DWC işlemi gösterilmiştir.



Şekil 3.9. Derinlemesine ayrılabilir konvolüsyon(DWC) [59].

MobileNetV2 mimarisinde, MobileNetV1 den farklı olarak ağırlık sayılarının azaltılması için çıkış kanallarının daraltıldığı bir darboğaz (bottleneck) oluşturulduğu görülmektedir ve derinlemesine ayrılabilir konvolüsyon işleminden önce noktasal konvolüsyon işlemi ile veri temsilleri için hacimsel gösterimden kaynaklı dezavantajı ortadan kaldırılarak performans artışı sağlamaktadır. Çizelge 3.1’de MobileNetV2 mimarisinin katman yapısı gösterilmiştir.

Çizelge 3.1. MobileNetV2 katman yapısı. t: genişleme faktörü, c: çıkış kanal sayısı, n: tekrar sayısı, s: adım.

Giriş	Operatör	t	c	n	s
$224^2 \times 3$	Konvolüsyon 2D	-	32	1	2

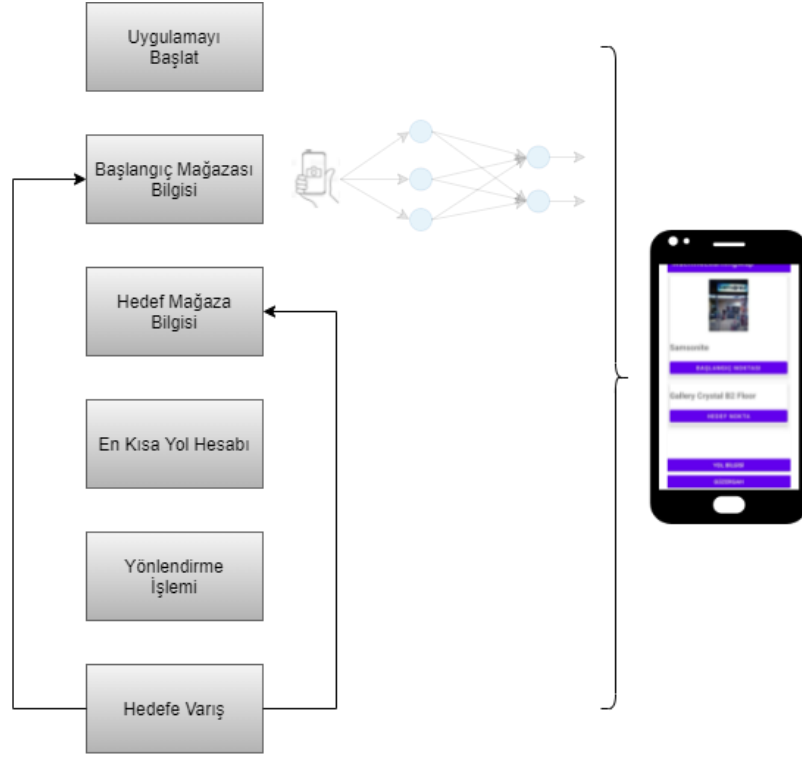
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	Konvolüsyon 2D 1 x 1	-	1280	1	1
$7^2 \times 1280$	Havuzlama 7 x 7	-	-	1	-
$1 \times 1 \times 1280$	Konvolüsyon 2D 1 x 1	-	k	-	-

BÖLÜM 4

SINIFLANDIRMA MODELİNİN TASARIMI VE İÇ MEKAN YÖNLENDİRME PROBLEMİNE UYGULANMASI

Bu proje, sık kullanılan derin öğrenme mimarisi ve en kısa yol algoritmalarının insanların kapalı alanlardaki yol bulma çalışmalarına katkı sağlamak için yapılmıştır. Proje de kullanıcının mevcut durumunu izleme takibi olmaksızın, bina modeli üzerinde yönlendirme adımını içermektedir. Proje, dış mekan yönlendirme sistemi ile ilgili değildir.

Bu iki temelden oluşan bir çalışmadır. Bunlardan biri Android uygulamada mevcut konumun belirlenmesi için, görüntülerden analiz gerçekleştiren bir derin öğrenme mimarisidir. İkincisi, bina yapılarına ait kat bilgilerini kullanarak, en kısa yol algoritması ile yol tespiti sağlayan Android işletim sistemi üzerinde çalışan bir mobil uygulamadır. Şekil 4.1’de uygulama iş akışı gösterilmiştir.



Şekil 4.1. Uygulama iş akış diyagramı.

4.1. VERİ SETİ

Türkiye nüfusunun %18,49'unun ikamet ettiği İstanbul'da alışveriş merkezlerindeki yoğunluk ve insanların bu mekanlarda ulaşım konusunda yaşadıkları sıkıntılar çalışma alanının belirlenmesinde etkili olmuştur. Çalışmada, İstanbul'da bulunan 6 katlı BuYaka alışveriş merkezi tercih edilmiştir. Alışveriş merkezindeki 158 farklı mağaza için farklı boyut ve açılardan Google aracılığı ile görüntüler toplanmıştır. Hazırlanan veri setinden örnek görüntüler Şekil 4.2' de görülmektedir.



Şekil 4.2. Eğitim için örnek veriler [60].

4.1.1. Veri Setinin Hazırlanması

Veri ön işleme, veriler üzerinden istenmeyen bilgilerin çıkartılmasını, kullanılmak istenilen bilgilerinde iyileştirilmesini amaçlamaktadır. Veri ön işleme adımları problemlere özgün olarak bir analiz niteliği taşımaktadır. Bu analiz verilerden gerekli bilgilerin elde edilmesi esasına dayanır. Veriler üzerinde gerçekleştirilen, veri temizleme, indirgeme, dönüştürme, birleştirme gibi birçok ön işleme teknikleri mevcuttur [61]. Bu teknikler ile verinin anlamlandırılması, eksik verilerin tespit edilmesi, tekrar boyutlandırılması, normalleştirilmesi sağlanarak kullanım amacına göre uygun hale getirilmesi sağlanır.

Veriler üzerinde dönüştürme işlemi normalizasyon ile gerçekleştirilir. Normalizasyon, giriş değeri üzerinde indirgeme anlamına gelmektedir. İndirgeme işlemi ile amaç farklılığın fazla olduğu verileri ortak bir sistem üzerinde karşılaştırabilmektir. Ondalık

normalizasyon, z-score normalizasyon ve min-max normalizasyon sık kullanılan yöntemlerdir.

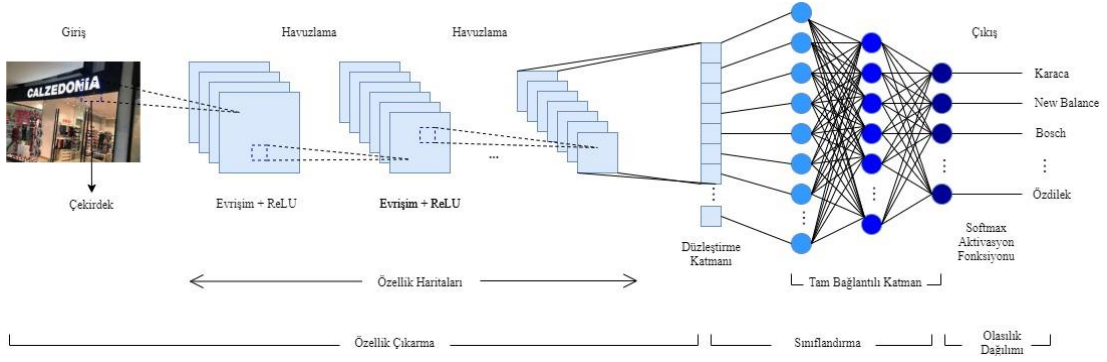
Çalışmada oluşturulan 8536 adet 3 kanal renk bilgisine sahip giriş görüntü veri seti, 0-255 aralığında gri seviyeli veri seti görüntüye dönüştürülmüştür. Giriş veri boyutu 224×224 olarak belirlenmiştir. Daha sonra Eşitlik 4.1 kullanılarak min-max normalizasyon işlemi uygulanmıştır. 0-255 aralığındaki gri seviye piksel değerleri 0-1 aralığına dönüştürülmüştür. Böylece 0: siyah, 1: beyaz ve aradaki değerlerin gri seviyeleri 0 ve 1'e yakınlıklarına göre temsil edilmektedir.

Uygulanan normalizasyon formülü:

$$x' = (x - \min(x)) \div (\max(x) - \min(x)) \quad (4.1)$$


4.2. MOBİLENETV2 İLE MAĞAZA GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

CNN mimarisi eğitilebilen birçok katman ve parametreden oluşmaktadır. Katmanlı yapısı ile ayrıntılı öz nitelikleri tespit ederek daha doğru sonuçlar ortaya koymaktadır. Bu nedenle, çalışmada kullanıcının bulunduğu yerdeki mağaza adının tespiti için çekilen görüntüleri sınıflandıran bir transfer öğrenmeye dayalı CNN modeli tercih edilmiştir. CNN mimarisi evrişim, havuzlama ve tam bağlı katman olarak üç kısımdan oluşmaktadır. Evrişim katmanı giriş verilerini filtreleyerek öznitelik haritalarını oluşturur. Bu şekilde özelden genele daha ayrıntılı nesnelere öğrenme gerçekleştirilir. Havuzlama katmanında öznitelikler örneklendirilerek boyut azaltılır ve parametre sayısındaki düşme ile modelin hızlı öğrenmesi sağlanır. Tam bağlı katman ile her nöron için bir önceki katmandan gönderilen giriş değerlerine göre uygun çıktı değerleri elde edilir. Şekil 4.3'de sınıflandırma modelinin ayrıntılı yapısı gösterilmiştir.




Şekil 4.3. CNN mimarisinin ayrıntılı yapısı.

Bu çalışmada, MobileNet V2 ile etiketlenmiş bir veri kümesiyle eğitim yapıldıktan sonra öğrenilmiş katsayılar kullanılarak seçilen bina için görüntü sınıflandırılması gerçekleştirilmiştir. Yeni veri kümesine göre tasarlanmış bir CNN'in evrişim katmanı ağırlık değerleri eğitilmiş bir CNN'den kopyalanır ve eğitim işlemi sadece sınıflandırma katmanında gerçekleştirilir. Böylece eğitilmiş CNN'in özellik çıkarma başarısı yeni CNN modeline aktarılmaktadır. Şekil 4.4'te sınıflandırma modeli için MobileNetV2 mimarisi ve Şekil 4.5'de MobileNetV2 darboğaz katmanı yapıları gösterilmiştir.



Şekil 4.4. Sınıflandırma için MobileNetV2 mimarisi.

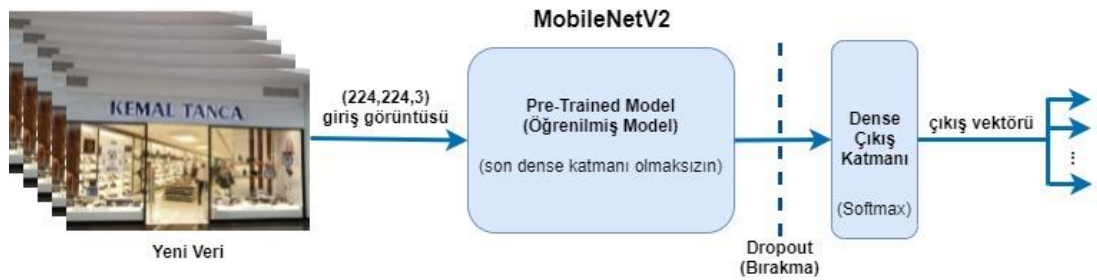


Şekil 4.5. MobileNetV2 darboğaz katmanı.

MobileNet V2 ilk olarak giriş görüntüleri için 3x3 kernel(çekirdek)ile Conv2D kullanarak özellik çıkarımı sağlamaktadır. Conv2D adımında sonra 19 darboğaz

katmanına (bottleneck layers) giriş yapılır. Darboğaz katmanı, 3 evrişim adımından oluşmaktadır. Bunlar 1x1 evrişim (convolution), 3x3 derinlemesine evrişim (depthwise convolution), and 1x1 noktasal evrişim (pointwise convolution). 1x1 evrişim, özellikleri zenginleştirmek için kanal sayısı artırılmaktadır. Derinlemesine evrişim ve noktasal evrişim ile de hesaplama maliyeti düşürülmektedir. Tüm katmanları toplu normalleşme (batch normalization) ve aktivasyon fonksiyonu (activation function) adımları izlemektedir. Batch normalization adımı ile gradyan bağımlılığı azaltılarak normalleştirme işlemi gerçekleştirilir. Aktivasyon fonksiyonu olarak son evrişim katmanı dışında ReLU6 kullanılmaktadır. ReLU6, ReLU fonksiyonundan daha güçlüdür ve hassas hesaplamalarda görüntülerden bilgileri tutabilme avantajına sahiptir.

Çalışma da TensorFlow Hub kullanılarak bir model tasarımı gerçekleştirilmiştir. TensorFlow Hub, öğrenme mimarilerinin yeniden revize edilerek farklı uygulamalarda kullanılmasını sağlayan bir kitaplık görevi görmektedir. Çalışmamız da transfer öğrenme modeli için ImageNet (ILSVRC-2012-CLS) [62] veri seti üzerinde MobileNet V2 mimarisi ile eğitilmiş görüntülerin özellik vektörleri kullanılmaktadır. Çalışmada tasarlanan modelin genel akışı Şekil 4.6'da gösterilmiştir.



Şekil 4.6. Tasarlanan modele genel bakış.

İlk olarak eğitim görüntü boyutları (224,224,3) olarak düzenlenmiştir. Gerekli normalizasyon işlemi gerçekleştirildikten sonra, MobileNet V2 modelinin özellik vektörleri kullanılarak, dropout katmanı eklenmiş ve sınıflandırma katmanında yapılan değişiklik ile çalışmaya uygun model tasarımı gerçekleştirilmiştir. Çalışmada tasarlanan model yapısı Şekil 4.7'de, oluşturulan model mimarisi de Çizelge 4.1'de gösterilmiştir.

```

1. model = tf.keras.Sequential([
2.   hub.KerasLayer(
3.     "https://tfhub.dev/google/tf2-preview/mobilenet_v2/feature_vector/4",
4.     output_shape=[1280], trainable=False),
5.   tf.keras.layers.Dropout(0.4),
6.   tf.keras.layers.Dense(train_generator.num_classes, activation='softmax')])

```

Şekil 4.7. Model yapısı.

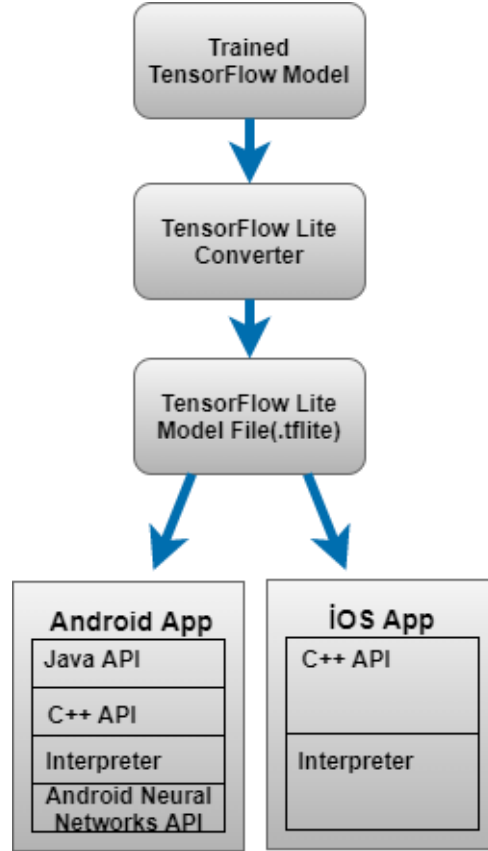
Çizelge 4.1. Eğitilmiş MobileNetV2 model mimarisi.

Katman	Çıkış Boyutu	Parametreler
keras_layer (KerasLayer)	(None, 1280)	2257984
dropout (Dropout)	(None, 1280)	0
dense (Dense)	(None, 158)	202398

4.3. SINIFLANDIRMA MODELİNİN ANDROİD İLE KULLANIMI

Yapay zekanın hayatımızın her alanında hızla yayılması ile gün geçtikçe artan bir talep ortaya çıkmaktadır. Bu noktada daha hızlı, kararlı, küçük cihazlarda verimliliği yüksek çözümler araştırma konusu olmuştur.

TensorFlow-Lite, Tensorflow modellerinin gömülü sistemlerde, mobil cihazlarda daha etkin kullanımını sağlayan bir araç setidir. Öğrenilen modellerin daha az gecikme süresi ile mobil cihazlarda kullanımını sağlamaktadır. Android, IOS gibi farklı platformları destekleyerek birçok programlama dili için API de sunmaktadır. Şekil 4.8'de eğitimi gerçekleştirilen bir modelin .tflite dönüşüm mimarisi gösterilmiştir.



Şekil 4.8. Modelin .tflite dönüşümü.

Mağaza görüntülerinin sınıflandırılması için oluşturulan model, dönüşüm işlemi ile birlikte Android ortamda kullanılacak .tflite uzantılı dosya olarak kaydedilir ve mağaza isimlerinin olduğu label dosyası ile android ortamda kullanılır.

4.3.1. Dijkstra Algoritması ile Yönlendirme

Bu çalışmada alışveriş merkezine ait kat planları bir graf modeli olarak ele alınmıştır. Mağazalara ait kapı numaraları köşeleri/düğümüleri, mağazaları birbirine bağlayan yollar çizgeleri ifade etmektedir. Aralarında mesafe/ilişki bazında bağlantı bulunan her uygulama için graf veri modeli kullanılabilir. Bir graf, köşelerden ve köşeleri birleştiren çizgelerden oluşmaktadır.

Grafların temsili gösterimleri:

$N(\text{Node}) = \{N_0, N_1, N_2, \dots\};$

$E(\text{Edge}) = \{E_0, E_1, E_2, \dots\};$

$G(\text{Graph}) = \{N, E\}$ şeklindedir.


N: Dügümü ,E: Kenarı ve G: Grafi temsil etmektedir.

Dijkstra algoritması belirlenen bir noktadan, istenilen noktaya olan en kısa mesafe bilgisini belirlemektedir. Ağırlıklandırılmış ve yönlü rota bilgilerini kullanarak işlemlerini gerçekleştirmektedir. Dijkstra algoritması en kısa mesafe bilgisini elde ederken Greedy (Açgözlü) yaklaşımını kullanmaktadır. Her adımda bir sonraki noktaya bu yaklaşım ile ilerleme gerçekleştirilir.

Uygulamada takip edilen Dijkstra algoritması işlem adımları:

- Görüntü sınıflandırma modeli ile mağaza görüntülerinden başlangıç mağazası belirlenir
- Uygulama üzerinden hedef mağaza seçimi yapılır
- Başlangıç mağazasından komşu mağazalara maliyet bilgisi hesaplanır
- En az maliyetli komşu mağaza seçilir
- Belirlenen her mağaza için komşu mağazalara olan en az maliyetli mağaza seçilerek her adımda bu işlem tekrar edilir
- Başlangıç mağazası ile hedef mağaza arasındaki yol ve maliyet bilgisi elde edilir

Şekil 4.9'da örnek olarak birbirine bağlı 7 nokta ve A noktasından diğer noktalara olan mesafe bilgileri verilmektedir.



Şekil 4.9. Örnek graf modeli.


Çizelge 4.2’ de A noktasından G noktasına olan en kısa yola ait mesafe bilgileri gösterilmiştir.

Çizelge 4.2. Noktalar arası en kısa yol mesafe bilgileri.

Gezilen noktalar	Bulunulan nokta	A	B	C	D	E	F	G
A	A	-----	3,A	6,A	4,A	∞	∞	∞
A-B	B		-----	5,B	4,A	6,B	∞	∞
A-B-D	D			5,B	-----	6,B	9,D	11,D
A-B-D-C	C			-----		6,B	8,C	11,D
A-B-D-C-E	E					-----	7,E	11,D
A-B-D-C-E-F	F						-----	8,E
A-B-D-C-E-F-G	G							-----

Dijkstra algoritması ile A noktasından G noktasına olan yol bilgisi A-B-D-C-E-F-G olarak elde edilmiş ve yol maliyeti 8 olarak hesaplanmıştır.

Çalışmada, Dijkstra algoritması ile başlangıç ve hedef nokta arasındaki güzergah bilgisi elde edilmiştir. Güzergah bilgisi ilgili katlara ait kat planları üzerinde kullanıcıya sunulmuştur. Aynı ve farklı kat üzerinde gerçekleşen yönlendirme işlemlerinde, birbiriyle komşu olan mağazaların ilişkileri ele alınmıştır. Farklı katlar arasında gerçekleşen yönlendirme işlemlerinde, yakın noktadaki asansör bilgisi göz önüne alınarak yönlendirme gerçekleştirilmiştir. Çalışmada kullanılan örnek kat plan görseli Şekil 4.10’da gösterilmiştir.



Şekil 4.10. Buyaka alışveriş merkezi örnek kat planı.

Alışveriş merkezindeki her kat planı için mağaza isimlerinin değişim durumu göz önüne alınarak kapı numaraları arasındaki komşulukları belirten komşuluk matrisi (Adjacency Matrice) oluşturulmuştur.

Komşuluk matrisi genel denklemi:

$$\begin{aligned} \text{Eğer } (Ni, Nj) \in E \text{ ya da } (Nj, Ni) \in E & \quad ,1 \\ \text{Diğer durumlarda} & \quad ,0 \end{aligned} \quad (4.2)$$

Burada Ni ve Nj iki noktayı (düğümü), E kenarları temsil etmektedir. Basit bir graf modeli için komşuluk matrisi oluşturulurken, eğer Ni ve Nj noktalarının birbirleri bir komşuluğu var ise, hem Ni noktasından Nj ye, hemde Nj noktasından Ni ye komşuluk belirtilebilir. Bu şekilde oluşturulan komşuluk matrisinde komşuluk durumu gözetmenler 1 ile, gözetmeyenler 0 ile temsil edilir.

Komşuluk matrisi üzerinde belirlenen kapı numarasının komşuları ile arasındaki komşulukların alınması, en yakın kapı bilgisinin güncellenmesi ve en kısa yol bilgilerinin tutulması işlemine ait pseudo code şöyledir Şekil 4.11’ de görülmektedir.

```
1. for (i = 1; i < toplamKapiNum; i++)
2.   {for kapiNumIndis=0; kapiNumIndis < toplamKapiNum; kapiNumIndis++) {
3.     if(!eklenmisKapiNum[kapiNumIndis]&&enkisaMesafeler[kapiNumIndis] <
       enkisaKapiMesafe)
4.       {enyakinKapi = kapiNumIndis;
5.         enkisaKapiMesafe = enyakinMesafeler [kapiNumIndis];}
6.     eklenmisKapiNum [enyakinKapi] = true;
7.     for (kapiNumIndis=0; kapiNumIndis < toplamKapiNum; kapiNumIndis++)
8.       {int kenarMesafe = mesafeMatrisi[enyakinKapi][kapiNumIndis];
9.         if (kenarMesafe > 0 && ((enkisaKapiMesafe+kenarMesafe) <
           enkisaMesafeler[kapiNumIndis]))
10.        {guzergah[kapiNumIndis] = enyakinKapi
11.          enkisaMesafeler[kapiNumIndis] = enkisaKapiMesafe + kenarMesafe;}}
```

Şekil 4.11. Söзде kod.

Çalışmanın Andorid ortamda kullanıcıya sunulması için bina yapıları Javascript Object Notation (json) formatında saklanmaktadır. Her kat planı için, içerisinde


mağaza adı, kapı numarası, kat bilgisi ve canvas üzerine yerleştirilen kat planlarına ait x, y nokta değerleri gibi bilgilerin bulunduğu json dosyası oluşturulmuştur.

Kat planına ait örnek json dosya bloğu Şekil 4.12’ de görülmektedir.

```
1.  {"id": 27,  
2.  "doorNumber": "27",  
3.  "name": "Arçelik",  
4.  "x": "637",  
5.  "y": "367",  
6.  "floor": "B2"}
```

Şekil 4.12. Kat planına ait json dosya bloğu.

Sınıflandırma modeli ile elde edilen mağaza adı bilgisi ve seçilen hedef mağaza adı bilgisi ilgili json dosyalarındaki kapı numaraları ile ilişkilendirilir. Dijkstra algoritması komşuluk matrisi üzerinden seçilen kapı numaraları arasındaki güzergah bilgisinin elde edilmesini sağlamaktadır. Android 2D çizim işlemleri için Canvas isimli bir sınıf kullanılmaktadır. Bu sınıf koordinat sistemini baz alarak kat planı üzerinde farklı stil işlemlerinin çizdirilmesini sağlamaktadır. Çalışmada başlangıç ve hedef nokta arasındaki güzergah Android için Canvas isimli bir sınıf kullanılarak gerçekleştirilmiştir. Şekil 4.13’de kat planı üzerinde canvas ile gerçekleştirilen yönlendirme gösterilmiştir.



Şekil 4.13. Canvas ile kat planı üzerinde yönlendirme.

BÖLÜM 5

DENEYSEL ÇALIŞMALAR

Bu bölümde oluşturulan sınıflandırma modelinin tasarım ortamı, modelin eğitim ve test sonuç bilgisi, Android uygulamasının tasarım aşamaları ve mobil yönlendirme sonuç bilgileri gösterilmiştir. Modelin eğitim başarımı ve mobil uygulama sonuçları çizelge ve şekillerle değerlendirilmiştir.

5.1. SINIFLANDIRMA MODELİ SONUÇLARI

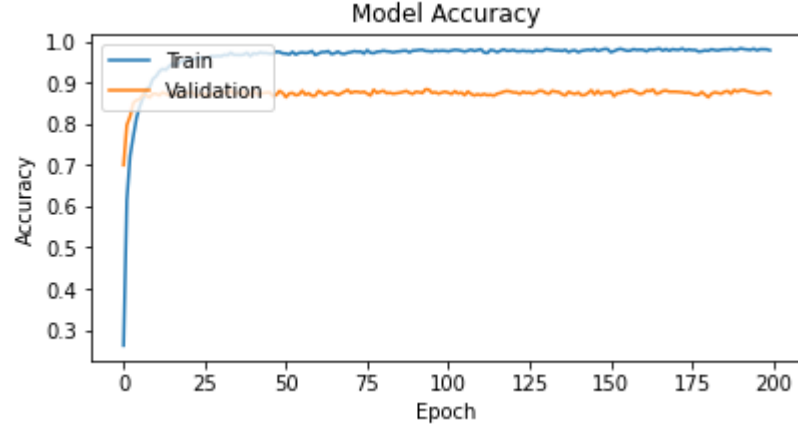
Çalışmada ele alınan sınıflandırma modeli Python dili kullanılarak Google Colab aracılığıyla eğitilmiştir. Çizelge 5.1’de modelin tasarlandığı bilgisayar ve kütüphane bilgileri verilmiştir.

Çizelge 5.1. Modelin tasarlandığı ortam özellikleri.


CPU	GPU	Bellek	İşletim Sistemi	TensorFlow
Intel Core i5-7200U CPU @2.40 Ghz	Intel(R) HD Graphics 620	8GB	Windows 10 Pro 64 bit	2.5.0

Colab kullanıcılara ücretsiz GPU desteği sağlayan bir bulut servisidir. NVIDIA Tesla K80 GPU üzerinde birçok derin öğrenme uygulamasının geliştirilmesini sağlamaktadır. Bu kısımda MobileNet V2 mimarisi ile eğitilen Buyaka veri setinin eğitim ve validation(doğrulama) grafikleri, test görüntüleri üzerindeki çıktı sonuçları gösterilmiştir.

Hazırlanan Buyaka veri setindeki 8536 görüntü üzerinden %80’i eğitim, %20’i doğrulama veri seti olarak belirlenmiştir. Tasarlanan CNN modeli 6890 eğitim, 1646 doğrulama görüntüsü ile eğitilmiştir. Şekil 5.1’de ve Şekil 5.2’de modelin 200 adım eğitim için doğruluk ve kayıp (loss) değerlerinin grafikleri gösterilmiştir.



Şekil 5.1. Modelin başarımlar grafiği.



Şekil 5.2. Modelin kayıp grafiği.

Toplam 8536 görüntü ile farklı adım sayılarında çalıştırılan model 200 adım sonucunda %98'lik doğruluk elde etmiştir. Modelin test işlemleri için veri artırımı (Data Augmentation) ile 158 sınıfa ait toplam 588 test görüntü verisi hazırlanmış ve %96 başarımlar elde edilmiştir.

Model başarımlar sonuçlarında aşırı öğrenme, modelin performansının rastgele olup olmadığını görmek için farklı yaklaşımlar mevcuttur. Çalışma da model performansının gösterilmesi için K Katlamalı Çapraz Doğrulama (K-Fold Cross Validation) işlemi gerçekleştirilmiştir. Çalışmada veriler 10 farklı kümeye ayrılarak işlem gerçekleştirilmiş ve her bir başarımlar sonuçları ile ortalama çapraz doğrulama başarımlar değeri Çizelge 5.2'de gösterilmiştir.

Çizelge 5.2. Çapraz doğrulama başarımları sonuçları.

Model	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	Fold 8	Fold 9	Fold 10	Ortalama
CNN	92.61	92.84	96.43	94.63	93.42	93.15	94.84	94.63	93.41	92.10	94

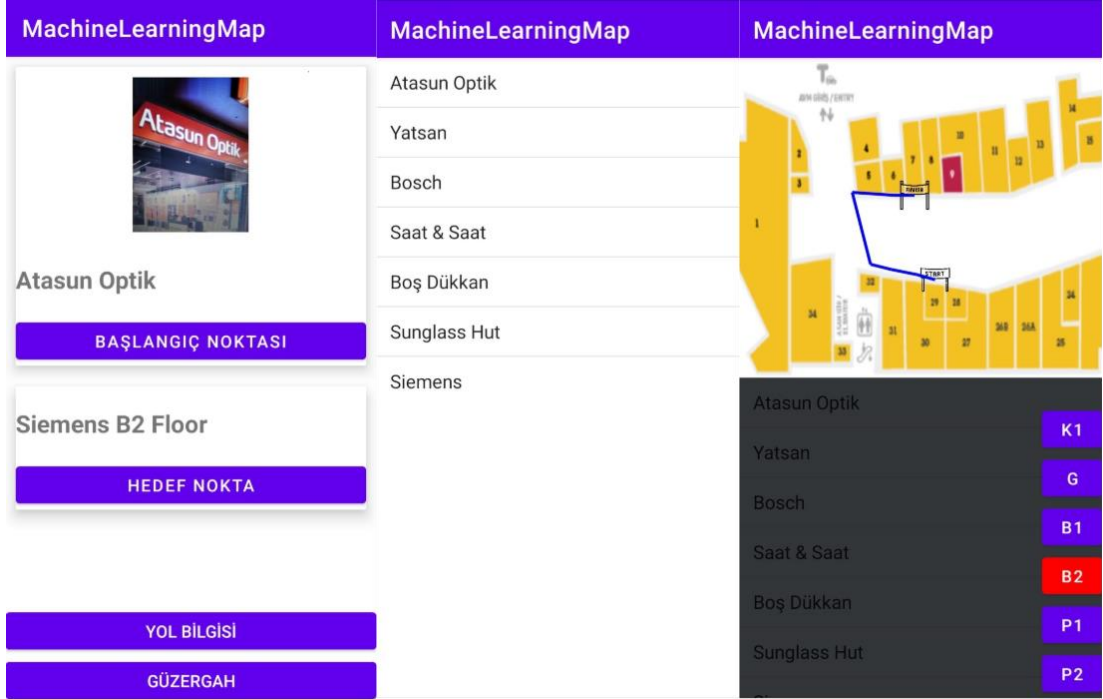
5.2. MOBİL UYGULAMA SONUÇLARI

Bu kısımda uygulamanın akıllı telefon (Redmi 8A MIUI Global 12.0.3) üzerindeki denemeleri ile çıktığı sonuçları verilmektedir. Çizelge 5.3’de akıllı telefonun teknik özellikleri gösterilmiştir.

Çizelge 5.3. Redmi 8A teknik özellikleri.

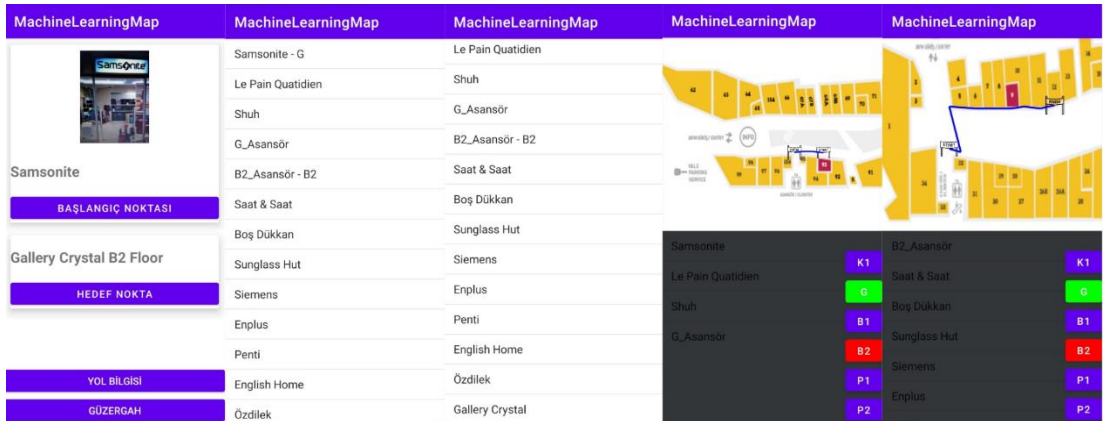
İşlemci	Sekiz Çekirdek Maks. 2.01GHz
Bellek	2 GB RAM
Kamera	12 MP , f / 1.8 , 1 / 2.55
Ekran Boyutu ve Çözünürlüğü	6.22 inç / 720x1520 (HD+) Piksel
İşletim Sistemi	Android 10.0

Uygulamanın akıllı telefon üzerindeki sonuçları gerçek veriler ile alınmıştır. Başlangıç bilgisi kullanıcının mağaza adını tespiti ile belirlenmiştir. Aynı ve farklı katlar arasında yönlendirme sağlanan çalışma da, farklı katlar arasındaki yönlendirme için kat planlarındaki asansör bilgisini kullanılmaktadır. Kullanıcı tarafından belirlenen ve seçilen mağaza isimlerine ait json dosyasındaki kat bilgisi aynı ise Dijkstra algoritmasına gönderilen kapı numaraları aynı kat üzerindeki yol bilgisi ve güzergah bilgisini sağlamaktadır. Şekil 5.3’de aynı kat üzerinde bulunan mağazalar için yol bilgisi ile güzergah bilgisi gösterilmiştir. Şekil 5.4’de farklı katlardaki mağazalar için yönlendirme adımları gösterilmiştir.



Şekil 5.3. Aynı kat üzerinde yönlendirme.

Aynı kat üzerinde bulunan Atasun Optik ve Samsung mağazaları için yol bilgisi komşuluklarına bakılarak Yol Bilgisi kısmında adım adım belirtilmiş ve GüzergaH kısmında kat planı üzerindeki bina yapısına uygun olarak çizim olarak gösterilmiştir.



Şekil 5.4. Farklı kat üzerinde yönlendirme.

Farklı katlar üzerinde gerçekleştirilen yönlendirme işleminde katlarda bulunan asansör noktası baz alınarak işlem yapılmıştır. Samsonite ve Gallery Crystal mağazaları için ilk olarak başlangıç noktası olan Samsonite mağazasından aynı kattaki asansöre kadar

yönlendirme sağlanmış, ikinci olarak Gallery Crystal mağazasının bulunduğu kattaki asansör noktasından Gallery Crystal mağazasına yönlendirme sağlanmıştır.

BÖLÜM 6

SONUÇLAR

Bu çalışmada, iç mekanlarda yönlendirme çalışmaları için farklı yaklaşımlar gösterilmiştir. Ancak iç mekanlarda donanımdan bağımsız olarak konum tespiti için derin öğrenme temelli yaklaşım ile başarımlar elde edildiği gözlemlenmiştir. Bu yaklaşım yönlendirme çalışmalarında tercih edilen yapılar için farklı uygulama metodlarının da kullanılmasına sebep olmaktadır. Derin öğrenme mimarilerinin başarımların değerleri kullanılan veri setindeki verilerin fazla olması ile doğru orantılıdır. Verilerin yetersiz olduğu durumlarda transfer öğrenmeye dayalı yaklaşımlar tercih edilmektedir. Bu çalışma bize tercih edilen alışveriş merkezi için oluşturulan özgün veri seti üzerinde transfer öğrenme ile CNN mimarisinin sınıflandırma başarımlarını göstermektedir. Oluşturulan CNN modeli ile yüksek hesaplama maliyetini ve veri miktarındaki dezavantajı ortadan kaldırmak için transfer öğrenme yaklaşımı tercih edilmiştir. Çalışmada diğer bir adım yönlendirme uygulamasının kullanıcıya sunulmasıdır. Bu noktada CNN modelinin android ortama entegrasyonu sağlanmıştır. Uygulama üzerinde başlangıç noktası için CNN modeli sonucunda başlangıç konum bilgisi alınmıştır. Uygulama üzerinde yönlendirme adımında en kısa yol algoritması olan Dijkstra algoritması ile yönlendirme işlemi sağlanmıştır. Çalışmada Dijkstra algoritmasının işlem süresi ve optimum sonuç avantajlarından yararlanılmıştır.

Çalışmamızda iç mekan görüntüleri ile gerçekleştirilen eğitim sonucunda hem görüntü sınıflandırma konusunda başarılı bir sonuç elde edilmiş hem de android ortamda sınıflandırma modeli aracılığıyla kullanıcıya yönlendirme sağlanmıştır. Yapılan çalışma, transfer öğrenme yaklaşımının iç mekanlarda kullanımına da katkı sağlamaktadır. Uygulamanın daha ileri sürümlerinde kullanıcıdan alınan geri dönüşler ile mağaza bilgileri değişim durumları kontrol edilerek model eğitime devam edilecektir.

KAYNAKLAR

1. Braden, K., Browning, C., Gelderloos, H., Smith, F., Marttila, C., and Vallot, L., "Integrated inertial navigation system/Global Positioning System (INS/GPS) for manned return vehicle autoland application", *IEEE Symposium on Position Location and Navigation. A Decade of Excellence in the Navigation Sciences*, 74–82 (1990).
2. Jung, S. hoon, Lee, S., and Han, D., "A crowdsourcing-based global indoor positioning and navigation system", *Pervasive And Mobile Computing*, 31: 94–106 (2016).
3. Puikkonen, A., Sarjanoja, A.-H., Haveri, M., Huhtala, J., and Häkkinen, J., "Towards designing better maps for indoor navigation", *Proceedings of the 8th International Conference on Mobile and Ubiquitous Multimedia*, 1–4 (2009).
4. Thrun, S., "Learning metric-topological maps for indoor mobile robot navigation", *Artificial Intelligence*, 99 (1): 21–71 (1998).
5. Chittaro, L., "Visualizing information on mobile devices", *Computer*, 39 (3): 40–45 (2006).
6. Mautz, R., "Overview of current indoor positioning systems", *Geodesy And Cartography*, 35 (1): 18–22 (2009).
7. Emrullah Demiral, İsmail Rakıp Karas, Muhammed Kamil Turan, 2013, "RFID Sistemleri ile Konum Belirleme Uygulamaları", *TMMOB Harita ve Kadastro Mühendisleri Odası, 14. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 90 (370): 14–17 (2013).
8. Ortakci, Y., Karas, I. R., Atila, U., and Demiral, E., "Intelligent Mobile Indoor Navigation System for Fire Evacuation Based on Artificial Neural Network", *International Journal Of Computer Science And Information Security*, 14 (11): 980–996 (2016).
9. Wang, C., Wu, F., Shi, Z., and Zhang, D., "Indoor positioning technique by combining RFID and particle swarm optimization-based back propagation neural network", *Optik*, 127 (17): 6839–6849 (2016).
10. Aldemir, O., Dinçer, Z., and Ayd, E., "Aktif RFID Sistemi Kullanarak İç Mekanda Yönlendirme", *Uluslararası Radyo Bilimleri Birliği Kongresi*, (January 2006): 468–470 (2020).
11. Mohri, M., "Semiring Frameworks and Algorithms For Shortest-Distance Problems", *J. Automata, Languages And Combinatorics*, 7 (3): 321–350

(2002).

12. R, A., "Path Finding Solutions For Grid Based Graph", *Advanced Computing: An International Journal*, 4: 51–60 (2013).
13. Galán-García, J. L., Aguilera-Venegas, G., Galán-García, M., and Rodríguez-Cielos, P., "A new Probabilistic Extension of Dijkstra's Algorithm to simulate more realistic traffic flow in a smart city", *Applied Mathematics And Computation*, 267: 780–789 (2015).
14. Chen, Y. Z., Shen, S. F., Chen, T., and Yang, R., "Path optimization study for vehicles evacuation based on Dijkstra algorithm", *Procedia Engineering*, 71 (October 2015): 159–165 (2014).
15. Ruan, C., Luo, J., and Wu, Y., "Map navigation system based on optimal Dijkstra algorithm", *CCIS 2014 - Proceedings Of 2014 IEEE 3rd International Conference On Cloud Computing And Intelligence Systems*, 559–564 (2014).
16. Özdemir, S., Sacar, Ö., and Özcan, E., "Dijkstra Algoritması Kullanılarak İpek Yolu Koridorları Arasında En Kısa Ulaştırma Güzergâhının Belirlenmesi", *Demiryolu Mühendisliği*, (13): 97–105 (2020).
17. Arıcı, V., "Engellerin Bulunduğu Ortamda Gezgin Robotun İyi Yolu Bulması ve İzlemesi", *Başkent Üniversitesi*, (2008).
18. Koca, G. O. and Doğan, Ş., "Üç boyutlu bir arama yüzeyi için mobil robotların yol planlaması", *BEÜ Fen Bilimleri Dergisi*, 8 (1): 298–307 (2019).
19. Xu, Y., Wen, Z., and Zhang, X., "Indoor optimal path planning based on Dijkstra Algorithm", *International Conference On Materials Engineering And Information Technology Applications*, (Meita): 309–313 (2015).
20. Ishak, A. J., Ata, K. I. M., Soh, A. C., Ishak, A. J., Jaafar, H., and Khairuddin, N. A., "Smart Indoor Parking System Based on Dijkstra's Algorithm", *Researchgate.Net*, 2 (1): 2600–7495 (2019).
21. Vanclooster, A., De Maeyer, P., Fack, V., and Van de Weghe, N., "Calculating least risk paths in 3D indoor space", *Lecture Notes In Geoinformation And Cartography*, XL (November): 13–31 (2014).
22. Fadzli, S. A., Abdulkadir, S. I., Makhtar, M., and Jamal, A. A., "Robotic indoor path planning using dijkstra's algorithm with multi-layer dictionaries", *2015 IEEE 2nd International Conference On Information Science And Security, ICISS 2015*, 1–4 (2016).
23. Xu, M., Wei, S., and Zlatanova, S., "An indoor navigation approach considering obstacles and space subdivision of 2D plan", *International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences - ISPRS*

- Archives*, 41 (August): 339–346 (2016).
24. Boguslawski, P., Mahdjoubi, L., Zverovich, V., and Fadli, F., "Two-Graph Building Interior Representation for Emergency Response Applications", *ISPRS Annals Of Photogrammetry, Remote Sensing And Spatial Information Sciences*, III-2 (June): 9–14 (2016).
 25. Dirik, M. and Kocamaz, A. F., "RRT- Dijkstra: An Improved Path Planning Algorithm for Mobile Robots", *Journal of Soft Computing and Artificial Intelligence*, 1 (2): 69-77 (2020).
 26. Şeker, A., Diri, B., and Balık, H., "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme", *Gazi Mühendislik Bilimleri Dergisi*, 3: (2017).
 27. Deng, J., Dong, W., Socher, R., Li, L., Kai Li, and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database", (2009).
 28. Kaya, A., Keçeli, A. S., and Can, A., "Akciğer nodül özelliklerinin tahmininde çeşitli sınıflama stratejilerinin incelenmesi", *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 2018: (2018).
 29. Dandıl, E. and Polattimur, R., "Dog behavior recognition and tracking based on faster R-CNN", *Journal Of The Faculty Of Engineering And Architecture Of Gazi University*, 35 (2): 819–834 (2020).
 30. Yıldız, O., "Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study", *Journal Of The Faculty Of Engineering And Architecture Of Gazi University*, 34 (4): 2241–2260 (2019).
 31. Kam, B. D., "Deep learning based dynamic turkish sign language recognition with leap motion", *Institute of Science And Technology*, (2020).
 32. Cireşan, D., Meier, U., and Schmidhuber, J., "Multi-column deep neural networks for image classification", *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 3642–3649 (2012).
 33. Cireşan, D. C., Meier, U., Masci, J., and Gambardella, L. M., "Flexible, High Performance Convolutional Neural Networks for Image Classification Dan", *Proceedings Of The Twenty-Second International Joint Conference On Artificial Intelligence Flexible*, 1237–1242 (2003).
 34. Farfade, S. S., Saberian, M., and Li, L. J., "Multi-view face detection using Deep convolutional neural networks", *ICMR 2015 - Proceedings Of The 2015 ACM International Conference On Multimedia Retrieval*, (January): 643–650 (2015).
 35. Grefenstette, E., Blunsom, P., de Freitas, N., and Hermann, K. M., "A Deep Architecture for Semantic Parsing", *Association for Computational*

Linguistics, 22–27 (2014).

36. Shen, Y., He, X., and Gao, J., "Learning Semantic Representations Using Convolutional Neural Networks for Web Search", *Proceedings of the companion of the 23rd international conference on World wide web companion*, 373–374 (2014).
37. Graves, A. and Jaitly, N., "Towards end-to-end speech recognition with recurrent neural networks", *31st International Conference On Machine Learning, ICML 2014*, 5: 3771–3779 (2014).
38. Karpathy, A. and Fei-Fei, L., "Deep Visual-Semantic Alignments for Generating Image Descriptions", *Cvpr*, (2015).
39. Salouhou, A., "El yazısı karakter tanıma ve resim sınıflandırmada derin öğrenme yaklaşımları", *Institute of Postgraduate Education*, 86-95 (2019).
40. Graves, A. and Schmidhuber, J., "Framewise phoneme classification with bidirectional LSTM and other neural network architectures" *Neural Netw.*, 18(5-6):602-10 (2005).
41. Fernández, S., Graves, A., and Schmidhuber, J., "An application of recurrent neural networks to discriminative keyword spotting", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 4669 LNCS (PART 2): 220–229 (2007).
42. Baccouche, M. and Mamalet, F., "Sequential Deep Learning for Human Action Recognition", *HBU*, 29–30 (2011).
43. Eck, D. and Schmidhuber, J., "Learning the long-term structure of the blues", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 2415 LNCS: 284–289 (2002).
44. Tekerek, A., Tekerek, M., and Babüroğlu, B., "Türkçe için derin öğrenme tabanlı doğal dil işleme", *13th International Computer and Instructional Technology Symposium (ICITS 2019)*, 671-679 (2019).
45. Wang, X., Xue, F., Wang, W., and Liu, A., "A network model of speaker identification with new feature extraction methods and asymmetric BLSTM", *Neurocomputing*, 403: 167–181 (2020).
46. Li, W., Qi, F., Tang, M., and Yu, Z., "Bidirectional LSTM with self-attention mechanism and multi-channel features for sentiment classification", *Neurocomputing*, 387: 63–77 (2020).
47. Altan, G., "DeepGraphNet: Grafiklerin Sınıflandırılmasında Derin Öğrenme Modelleri", *European Journal Of Science And Technology*, (October): 319–

327 (2019).

48. Tasdelen, A. and Sen, B., "A hybrid CNN-LSTM model for pre-miRNA classification", *Scientific Reports*, 11 (1): 1–10 (2021).
49. Sengur, A., Akbulut, Y., Guo, Y., and Bajaj, V., "Classification of amyotrophic lateral sclerosis disease based on convolutional neural network and reinforcement sample learning algorithm", *Health Information Science And Systems*, 5 (1): (2017).
50. Kim, Y., "Convolutional Neural Networks for Sentence Classification", *2017 43rd Latin American Computer Conference, CLEI 2017*, 2017-Janua: 1–5 (2017).
51. Fei-Fei, L., Deng, J., and Li, K., "ImageNet: Constructing a large-scale image database", *Journal Of Vision*, 9 (8): 1037–1037 (2010).
52. Weiss, K., Khoshgoftaar, T. M., and Wang, D. D., "A Survey of Transfer Learning", *Journal of Big Data*, *Springer International Publishing*, (2016).
53. Fırıldak, K. and Talu, M. F., "Evrışimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi", *Anatolian Journal Of Computer Science*, 4 (2): 88–95 (2019).
54. Kang, Y., Cho, N., Yoon, J., Park, S., and Kim, J., "Transfer learning of a deep learning model for exploring tourists' urban image using geotagged photos", *ISPRS International Journal Of Geo-Information*, 10 (3): (2021).
55. Šerić, L., Pinjušić, T., Topić, K., and Blažević, T., "Lost person search area prediction based on regression and transfer learning models", *ISPRS International Journal Of Geo-Information*, 10 (2): (2021).
56. Shen, D., Wu, G., and Suk, H.-I., "Deep learning in medical image analysis", *Annual Review Of Biomedical Engineering*, 19 (1): 221–248 (2017).
57. Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications", *Computer Vision and Pattern Recognition*, (2017).
58. Zhu, M. and Liu, M., "Mobile Video Object Detection with Temporally-Aware Feature Maps", *Proceedings Of The IEEE Computer Society Conference On Computer Vision And Pattern Recognition*, 5686–5695 (2018).
59. Metlek, S. and Çetiner, H., "Matlab Ortamında Derin Öğrenme Uygulamaları", *İksad Yayınevi*, 23-30 (2021).
60. İnternet: Buyaka Alışveriş Merkezi, "Buyaka Alışveriş Merkezi Mağazalar", <https://www.buyaka.com.tr/magazalar> (2022).

61. Oğuzlar, A., "Veri Ön İşleme", *Erciyes Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 0 (21): 67–76 (2003).
62. Internet: ImageNet, "ImageNet Large Scale Visual Recognition Challenge 2012 (ILSVRC2012)", <https://image-net.org/challenges/LSVRC/2012> (2022).

ÖZGEÇMİŞ

Ebru SOMUNCU ilk, orta ve lise öğrenimini Zonguldak'ta tamamladı. Yayla Mesleki ve Teknik Anadolu Lisesi Bilişim Teknolojileri Bölümü'nden 2011 yılında mezun oldu. 2011 yılında Bursa Uludağ Üniversitesi Bilgisayar Programcılığı Bölümü'nde Ön Lisans eğitime başlayıp 2013 yılında mezun oldu. DGS sınavı ile 2014 yılında Lisans eğitimi için Karabük Üniversitesi Bilgisayar Mühendisliği Bölümü'nde öğrenimine başlayarak 2018 yılında mezun oldu. 2019 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda Yüksek Lisans eğitime başladı ve eğitimini Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı altında sürdürmektedir. Aralık 2021 itibari ile Bartın Üniversitesi Mühendislik, Mimarlık ve Tasarım Fakültesi Bilgisayar Mühendisliği bölümünde Araştırma Görevlisi olarak göreve başladı.