

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**MALATYA İLİNDE GÖRÜNTÜ İŞLEME TABANLI AKILLI
KAVŞAK UYGULAMASI**

Emrullah EZBERCİ

Yüksek Lisans Tezi
EKOİLİŞİM ANABİLİM DALI

OCAK 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ekobilişim Anabilim Dalı

Yüksek Lisans Tezi

MALATYA İLİNDE GÖRÜNTÜ İŞLEME TABANLI AKILLI KAVŞAK UYGULAMASI

Tez Yazarı
Emrullah EZBERCİ

Danışman
Doç. Dr. Derya AVCI

OCAK 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ekobilişim Anabilim Dalı

Yüksek Lisans Tezi

Başlığı: Malatya İlinde Görüntü İşleme Tabanlı Akıllı Kavşak Uygulaması
Yazarı: Emrullah EZBERCİ
İlk Teslim Tarihi: 13.12.2021
Savunma Tarihi: 14.01.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

İmza

Danışman:	Doç. Dr. Derya AVCI Fırat Üniversitesi, Teknik Bilimler MYO	Onayladım
Başkan:	Doç. Dr. Özay YILDIRIM Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Doç. Dr. Eser SERT Malatya Turgut Özal Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Malatya İlinde Görüntü İşleme Tabanlı Akıllı Kavşak Uygulaması” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından TBMYO.21.01 numaralı proje ile desteklenmiştir.

14.01.2022

Emrullah EZBERCİ



ÖNSÖZ

Son yıllarda şehir nüfuslarının azami ölçüde artmasından dolayı kentlerin sahip oldukları kaynaklar yetersiz gelmektedir. Özellikle sensörler, internet bağlantı hızları, büyük veri, bulut bilişim ve yapay zekâ teknolojilerinde meydana gelen hızlı gelişmelerle nesnelerin internete bağlanarak akıllı cihazlara dönüştürülmesi gerçekleştirilmiştir. Böylelikle kaynakların şehir yaşamında daha verimli kullanılması ve şehirlerin yaşanabilir hale getirilmesi sağlanmıştır. Şehirlere kurulan sensörler ile elde edilen veriler öncelikle sensörlerin bağlı olduğu akıllı cihazlar sayesinde bulut teknolojisine aktarılarak buradaki yapay zekâ teknolojisi ile veri analizleri yapılmaktadır. Analiz sonucunda elde edilen değer ile şehir kaynaklarının kontrol ve yönetilmesi ile sürekliliğinin sağlanması hedeflenmektedir. Bu çalışmada Malatya Büyük Şehir Belediyesi tarafından kullanılan bir akıllı şehir uygulaması olan “ akıllı kavşak sistemi ” incelenmiştir. Uygulamanın özellikle şehir trafiğine ve diğer iyileştirmeler açıklanmıştır. Sistemin çalışma mantığı incelenmiş olup temin edilen görüntülerle dörtlü bir kavşak sisteminin uygulama simülasyonu C# ve Python dilleri kullanılarak araç sayına göre trafik ışık sürelerinin optimizasyonu gerçekleştirilmiştir.

Çalışmalarım sırasında yakın ilgi, anlayış gördüğüm ve beni destekleyip motive eden danışman hocam Doç. Dr. Derya AVCI'ya ve tez konusu için önerilerde bulunan Prof. Dr. Engin AVCI'ya, akıllı kavşak sistemini inceleme fırsatı tanıyan ve çalışmalarım için görüntü verisi desteğinde bulunan Malatya Büyükşehir Belediyesi'ne ve tez çalışmasının her aşamasında yanımda olan maddi manevi katkısını hissettiren dert ortağım sevgili eşim Fatma Feyza EZBERCİ ve çocuklarıma en içten teşekkürlerimi sunarım.

Emrullah EZBERCİ
ELAZIĞ, 2022

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
2. AKILLI ŞEHİRLER	4
2.1. Akıllı Şehir Nedir?	4
2.2. Akıllı Şehir Bileşenleri.....	5
2.2.1. Akıllı Ekonomi	6
2.2.2. Akıllı İnsan	6
2.2.3. Akıllı Devlet/Yönetim	6
2.2.4. Akıllı Ulaşım	6
2.2.5. Akıllı Çevre	7
2.2.6. Akıllı Yaşam.....	7
2.3. Nesnelerin İnterneti.....	8
2.4. Büyük Veri.....	8
2.5. Bulut Bilişim.....	11
2.6. Nesnelerin İnternetinin (IoT) Çalışma Prensibi	12
2.7. IoT'lerde Güvenlik.....	13
2.8. Akıllı Şehir Uygulamaları	14
2.8.1. Akıllı park sistemleri	14
2.8.2. Akıllı kavşak sistemleri	15
2.8.3. Akıllı Durak Sistemleri.....	16
2.8.4. Akıllı Atık Toplama Sistemi.....	17
2.8.5. Akıllı Park Sulama Sistemi.....	17
2.8.6. Akıllı Aydınlatma Sistemi	18
3. AKILLI KAVŞAK SİSTEMİ	19
3.1. Dinamik Kavşak Sistemi	19
3.2. Trafik Kontrol Merkezi	21
4. DERİN ÖĞRENME İLE NESNE ALGILAMA	24
4.1. Yapay Zekâ	24
4.1.1. Makine Öğrenmesi	26
4.1.2. Derin Öğrenme.....	28
4.2. Evrişimsel Sinir Ağları.....	28
4.2.1 Evrişimsel Sinir Ağı Katmanları	29
4.2.1.1 Önişleme katmanı	29
4.2.1.2 Evrişim katmanı.....	30
4.2.1.3 Aktivasyon Fonksiyonu Katmanı	31
4.2.1.4 Havuzlama katmanı	32

4.2.1.5 Dropout Katmanı	32
4.2.1.6 Tam bağı katmanı	32
4.2.1.7 Sınıflandırma Katmanı.....	32
4.2.2. Derin Öğrenme Algoritmaları.....	33
4.2.2.1 YOLO (You Only Looked Once)	33
4.2.2.2 RetinaNet	34
4.2.2.3 R-FCN	34
4.2.2.4 SSD mobileNet	35
4.2.3. Modellerin doğruluk ve zaman karşılaştırılması.....	35
5. MATERYAL VE METOT.....	37
5.1. Veri Setinin Hazırlanması.....	37
5.2. Veri Etiketleme	38
5.3. Modelin Eğitilmesi	39
6. BULGULAR VE TARTIŞMA	46
7. SONUÇLAR.....	47
KAYNAKLAR	48
ÖZGEÇMİŞ	

ÖZET

Malatya İlinde Görüntü İşleme Tabanlı Akıllı Kavşak Uygulaması

Emrullah EZBERCİ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

Ekobilişim Anabilim Dalı

Ocak 2022, Sayfa: xii + 49

Son yıllarda kırsaldan kentlere olan göç artışından dolayı merkezlerdeki nüfusun azami ölçüde artması ile kent kaynakları yetersiz gelmektedir. Ulaşım, güvenlik, çevre, sağlık, yönetim, ekonomi alanlarında birçok problemin oluşmasına sebep olmuştur. İşte bu problemleri çözerek şehirleri daha yaşanabilir ve yönetilebilir hale getirmek için akıllı şehir kavramı geliştirilmiştir. Sensörler, internet bağlantı hızları, büyük veri, bulut bilişim, yapay zekâ, nesnelerin interneti gibi teknolojik alanlardaki gelişmeler sayesinde şehirlerde kullanılan ulaşım, otoparklar, duraklar, atık toplama, aydınlatma gibi birçok alanda akıllı uygulamaları gerçekleştirilmektedir.

Şehir içi ulaşımında yolların birbirine bağlanmasını sağlayan kavşaklar trafik akışında önemli bir yere sahiptir. Normal kavşak sistemlerde trafik ışıklarının süreleri sabit olarak belirlenir. Trafikte araç sayısı çok fazla ya da hiç araç olmasa bile belirtilen sürede araçlar ve yayalar beklemek zorundadır. Akıllı kavşak sistemlerinde trafik ışıklarının süreleri araç yoğunluğa göre otomatik olarak belirlenir. Bu sistemlerde iki yöntem kullanılmaktadır. Birinci yöntemde, kamera sistemi ile kavşaktaki araç sayıları görüntü işleme yöntemleriyle hesaplanmaktadır. Araç sayısına göre sinyalizasyondaki bekleme süresi optimize edil. İkinci yöntemde ise kavşaklardaki yollara yerleştirilen sensörler tarafından araç sayısı belirlenmektedir. Daha sonra araç yoğunluğu fazla olan tarafa sistem tarafından geçiş üstünlüğü verilerek trafik yoğunluğunun önüne geçilmektedir. Ayrıca bu sistemde uzaktan merkezi yönetim ile müdahale edilebilmektedir.. Yollara geçiş üstünlükleri manuel olarak verilebilir. Malatya Büyük Şehir Belediyesi ulaşım biriminden alınan özel izinle kullanılan akıllı kavşak sistemi incelenmiştir. Bu sistemin çalışması ve sağlamış olduğu faydalar vurgulanmıştır. Ayrıca kavşaklardaki veri görüntülerinden araç tespiti için açık kaynaklı sinir ağı çerçevesi olan DARKNET'in gerçek zamanlı nesne algılama sistemi YOLOV3 derin öğrenme modeli kullanılmıştır.. Araçların sayımı ve sınıflandırılması anlık tespit edilerek veritabanına kaydedilmiştir. Program arayüz ile buradaki anlık bilgilerle sinyalizasyonun dinamik olması sağlanmıştır. Böylelikle yakıt tasarrufu, zaman ve araçların egzozlarından çevreye daha az zehirli gazların yayılması sağlanmaktadır. Temiz çevre oluşumuna katkı sağlanmış olur.

Anahtar Kelimeler: Akıllı Şehir, Akıllı Ulaşım, Akıllı Kavşak, Görüntü İşleme, Derin Öğrenme, Darknet, Yolov3

ABSTRACT

Image Processing Based Smart Intersection Application in Malatya Province

Emrullah EZBERCİ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Eco-informatics

January 2022, Pages: xii + 49

Due to the increase in migration from rural to urban areas in recent years, urban resources are insufficient with the maximum increase in the population in the centers. It has caused many problems in the fields of transportation, security, environment, health, management and economy. By solving these problems, the concept of smart city has been developed to make cities more livable and manageable. With technological developments such as sensors, internet connection speeds, big data, cloud computing, artificial intelligence, internet of things, smart transportation, smart parking, smart stop, smart waste collection, smart lighting etc. smart city applications have been realized and continue to be implemented.

One of the most important components used in smart transportation systems is smart intersection systems. In normal intersection systems, the duration of traffic lights is determined as fixed. Vehicles and pedestrians have to wait within the specified time even if there are not many or no vehicles in the traffic. In smart intersection systems, the duration of the traffic lights is determined automatically according to the vehicle density. Two methods are used in these systems. In the first method, the camera system and the number of vehicles at the intersection are calculated by image processing methods. Optimize the waiting time in signaling according to the number of vehicles. In the second method, the number of vehicles is determined by the sensors placed on the roads at the intersections. Then, the traffic density is prevented by giving the right of way to the side with high vehicle density by the system. In addition, in this system, it is possible to intervene remotely with the central management. Passing privileges to the roads can be given manually. The smart intersection system, which is used with a special permission from the Malatya Metropolitan Municipality transportation unit, has been examined. The operation of this system and the benefits it provides are emphasized. In addition, DARKNET's real-time object detection system YOLOV3 deep learning model, which is an open source neural network framework, was used for vehicle detection from data images at intersections. Counting and classification of vehicles were instantly detected and recorded in the database. With the program interface, it is ensured that the signaling is dynamic with the instant information here. Thus, fuel savings, time and emission of less toxic gases from vehicle exhausts to the environment are ensured. It contributes to the creation of a clean environment.

Keywords: Smart City, Smart Transportation, Smart Junction, Image Processing, Deep Learning, Darknet, YOLOV3.

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Akıllı şehir kavramı.....	5
Şekil 2.2. Akıllı şehir bileşenleri	5
Şekil 2.3. Büyük veri değer piramidi.....	9
Şekil 2.4. IoT yönetim	10
Şekil 2.5. Dünyanın en değerli kaynağı veri.....	11
Şekil 2.6. Bulut bilişim (Cloud Computing).....	12
Şekil 2.7. IoT çalışma prensibi	13
Şekil 2.8. IoT güvenliği.....	14
Şekil 2.9. Akıllı park sistemi	15
Şekil 2.10. Akıllı kavşak sistemi	16
Şekil 2.11. Akıllı durak sistemi	16
Şekil 2.12. Akıllı atık toplama sistemi	17
Şekil 2.13. Akıllı sulama sistemi.....	18
Şekil 2.14. Akıllı aydınlatma sistemi.....	18
Şekil 3.1. Malatya AKS balık gözlü kamera	20
Şekil 3.2. Malatya AKS sayım kamerası.....	20
Şekil 3.3. AKS kontrol merkezi	21
Şekil 3.4. Kavşakların uzaktan takibi ve yönetimi	22
Şekil 3.5. Kavşakların yoğunluk haritaları	22
Şekil 3.6. Kavşak sinyal planları	23
Şekil 3.7. Kavşak araç sayım verileri	23
Şekil 4.1. Makine öğrenmesi	27
Şekil 4.2. Klasik konvolüsyonel derin öğrenme algoritmalarının çalışma prensibi	28
Şekil 4.3. Evrişimsel sinir ağı mimarisi.....	29
Şekil 4.4. Evrişim işleminin görselleştirilmesi	30
Şekil 4.5. Evrişim işleminin özellik çıkarımı	31
Şekil 4.6. Yolo algoritmasının çalışması.....	33
Şekil 4.7. RetinaNet model mimarisi.....	34
Şekil 4.8. R-FCN mimari yapısı	35
Şekil 4.9. R-FCN mimari yapısı	35

Şekil 5.1. Veri seti örneği	38
Şekil 5.2. Uygun olmayan veri	38
Şekil 5.3. Veri Etiketleme	39
Şekil 5.4. Modelin eğitim iterasyon grafiği	40
Şekil 5.5. Modelin test edilmesi	40
Şekil 5.6. Akıllı kavşak Anamenü	41
Şekil 5.7. Malatya Belediyesi kavşak görüntü verileri	41
Şekil 5.8. Kavşak görüntüsünün alınması	42
Şekil 5.9. Araçların Sayım aşaması	43
Şekil 5.10. Nesne algılama	43
Şekil 6.1. Makine öğrenmesi	46
Şekil 6.2. Derin öğrenme.....	46

TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. Akıllı şehir bileşenleri.....	7
Tablo 4.1. Derin öğrenme modellerin ortalama doğruluk ve zaman karşılaştırılması	36
Tablo 5.1. Tespit edilen nesnelerin özellikleri	43
Tablo 5.2. Araç sayısına göre yeşil ışık süreleri	44



SİMGELER VE KISALTMALAR

Kısaltmalar

AKS	: Akıllı kavşak sistemi
AUS	: Akıllı ulaşım sistemi
IOT	: Nesnelerin interneti
YOLO	: You only looked once
ESA	: Evrişimsel sinir ağı



1. GİRİŞ

Birleşmiş Milletlerin kentleşme değerlendirmelerinde günde ortalama 200.000 kişinin kırsal alanlardan şehir merkezlerine doğru göç ettiği yer almaktadır. Bu da dünya nüfusunun büyük bir çoğunluğun kentlerde yaşadığı anlamına gelmektedir. İnsanların gelişen ve değişen talepleri, yüz ölçümleri, küresel ısınma, farklı demografik geçişler gibi faktörler şehirlerin ihtiyaçlarını şekillendirmektedir [1]. Günümüzde şehirlerde yaşanan insanların enerji, sağlık, eğitim, gıda, su, güvenlik gibi yaşamsal ihtiyaçları kamu tarafından karşılanmaktadır. Özellikle kent nüfusunun artması ve göç gibi olgular kentlerdeki kaynakların ekonomik, verimli ve adil olarak dağıtılması [2] ve kentlerin daha yaşamsal olarak cazip hale getirerek tercih edilmelerini sağlamak belediyelerin gündemine daha fazla taşınmaktadır. Oluşan bu problemleri çözmek ve hedeflenen amaçlara ulaşmak için gelişen yeni teknolojileri kullanarak çözüm üretmeye çalışılmakta, şehirleri kaliteli, yaşam düzeyini arttırıcı ve daha işlevsel mekânlara dönüştürülmesi hedeflenmektedir. Kentlerden oluşan problemlerle mücadele etmedeki hızlı çözüm arayışları, şehirleri daha “akıllı” hale getirmek için ülkeleri harekete geçirmektedir [3]. Kentleri sürdürülebilir ve yaşanabilir noktaya taşımak akıllı kent olgusundan geçmektedir. Aslında bilgi iletişim teknolojileri, sorun çözme becerisi ve yenilik gibi üç ana özelliğin akıllı kent yönetim sisteminin taşıması gerekmektedir. Akıllı kent uygulamaları karar alma sürecinde vatandaş katılımının sağlanması ile teknolojiyi en iyi şekilde kullanmalıdır. Özellikle kentlerdeki hızlı nüfus artışı ve kaynakların israf edilerek kullanılmasından dolayı oluşan kaynak kıtlığı tehditleriyle mücadele için üretilen yeni teknolojilerin uyum içerisinde birlikte düzenli olarak çalışması hedeflenmelidir [4]. Akıllı kent hizmetlerini geliştirmek ve işletmek için nesnelerin interneti (IoT), kablosuz sensor ağları (WSN'ler), insansız hava araçları, büyük veri analizleri ve bulut teknolojileri gibi bilişim argümanlarından faydalanılmalıdır [5]. Ayrıca sosyal medya, sosyal etkileşimli robotlar, büyük veri ve mobil uygulamalar ile desteklenmelidir. IoT teknolojisindeki gelişmelerin büyük bir kısmı akıllı şehir uygulamalarında kullanılmaktadır. Amaçlanan bu teknolojik uygulamalarla şehirlerin yaşanabilirliğini arttırmayı sağlamaktır [6]. Geliştirilen uygulamaların yapısında kullanılan sensörler yardımı ile büyük yapıda veriler oluşturulması sağlanmaktadır. Daha sonra bu veriler değerli bilgi parçaları haline çevrilerek şehir problemlerinin çözümüne ışık tutmaktadır.

Şehirleşmedeki nüfus artışından dolayı kentlerde kullanılan araçların sayılarında önemli oranda artış olmaktadır. Trafiklerdeki bu araç yoğunluğundan kaynaklanan zaman, çevre kirliliği ve gereksiz yakıt tüketimi gibi problemlerin oluşmasına sebebiyet vermektedir. Bu problemlerin çözümü için özellikle ışıklarda bekleyen araç yoğunluklarını önlemek ve hızlı geçiş sağlamak için bilgi teknolojilerinden faydalanılarak geliştirilen akıllı sistemlere ihtiyaç duyulmaktadır. Şehirlerdeki ulaşım akıllı hale getirilmesi için birçok parametre vardır. Bunlardan en önemlisi ise

araçların trafik ışıklarındaki bekleme sürelerini azaltılarak buralardaki araç yoğunluğunun önüne geçilmesi hedeflenmektedir. Bunun neticesinde akıllı kavşak uygulamaları geliştirilmiştir. Akıllı kavşak uygulamalarında manyetik tabanlı, ultrasonik tabanlı ve görüntü tabanlı sistemler kullanılmaktadır. Özellikle işlevselliğinin çok yönlü olması, kurulumunun kolaylığı, yönetilmesinin basitliği ve devamlılığının uzun olması etkenlerinden dolayı görüntü tabanlı sistemleri tercih edilmektedir. Bu sistemlerde bulunan kamera ile gerçek zamanlı alınan görüntüler görüntü işleme yazılımı ile anlık olarak araç yoğunluğu tespit edilerek trafik akışının yönlendirilmesi sağlanmaktadır. Trafik akışını kontrol eden ışıklarda belli bir süre olmayıp araç yoğunluğuna göre ışıkların zaman süreleri belirlenmektedir. Kentselde artan nüfus ile buna bağlı olarak araç sayısı yolların kontrol edilmesini güç hale getirmektedir. Bu problemin en önemli sebebi ise anlık kontrolün olmamasıdır [7].

Günümüzde trafik sinyalizasyonu kontrol etmek için yol altına döşenen sinyal dedektörleri ile oluşturulan sistemlerdir. Bu sistemin kurulumu, işletilmesi, bakımı ve maliyeti fazla olduğundan dolayı yapay zeka tabanlı kamera ile araç algılama sistemleri geliştirilmiştir [8].

Son yıllarda görüntü işleme konusunda yapılan çalışmalarda hız ve doğrulukta yüksek düzeyde başarılar elde edilmiştir. Bu başarıda en önemli faktör ise derin öğrenme algoritmaları önemli rol oynamaktadır. Özellikle görüntü, ses analizleri, robotik, gen, otonom sistemler ve tıp alanındaki nesnelerin tespit ve sınıflandırılmasında bu algoritmalar büyük doğruluk oranları ile birçok alanda kullanılmaktadır [9].

Ulaşımdan, park yeri bulmaya, trafik yoğunluğundan otonom araç geliştirilmesi ile savunma alanındaki hedef tespitine kadar birçok alan araç tespit sistemleri ile gerçekleştirilmektedir. Özellikle drone ve trafik kameralarından gelen görüntülerin sistemlerin performans ve ölçeklenebilirliklerinin daha hızlı ve daha doğru bir şekilde tanımlanmasının sağlanması için derin öğrenme, makine öğrenmesi yöntemleri ve görüntü işleme algoritmalarının kullanılmasının gerekliliği ortaya çıkmıştır. Derin öğrenme yöntemlerinde konvolüsyonel ağ modeli ve görüntü işleme ve nesne tespiti yönteminde ise YOLO algoritmaları ön plana çıkmaktadır [10].

Normal makine öğrenmesi yöntemlerine göre çok katmanlı sinir ağları resimlerdeki nesnelerin tespit ve sınıflandırılmasında çok daha iyi sonuçlar alarak en iyi olduğunu kanıtlamıştır. 2012 yılında Alex ve arkadaşları ImageNet yarışmasında çok katmanlı evrimsel sinir ağları kullanarak derin öğrenme yönteminin diğer yöntemlere göre %16,42 hata oranı ile iyi bir performans göstermiştir [11]. Sınıflamada kullanılan ImageNet verilerine göre en iyi insan hata seviyesi %5,1 seviyesindeyken PreLU-Net %4,94 hata oranı ile insan doğruluk oranını geçen ilk yapay sinir ağı olmuştur. 2019 yılında EfficientNET ile bu değer %2.9 değerine gelmiştir [12].

Yapılan incelemelerde Malatya B y k Őehir Belediyesi'ne ait bu sistemlerde klasik g r nt  iŐleme teknolojileri kullanılmaktadır. Bu  alıŐmamızda geleneksel g r nt  iŐleme algoritmalarının aksine bir yapay zek  olan derin  ğrenme teknolojisi ile ıŐıklardaki ara lar tespit edilerek ara  sayısı bulunarak ıŐık s relerinin dinamik olarak deėiŐmesi saėlanmaktadır.



2. AKILLI ŞEHİRLER

2.1. Akıllı Şehir Nedir?

Şehirler, içerisinde yaşayan farklı amaçlara sahip insanlara yaşam kalitesi sağlayarak sürdürülebilir bir çevrede birliği içerisinde yaşamaya zorlanan alanlar olarak karşımıza çıkmaktadır [13]. Dinamik bir yapıya sahip kentler hızlı nüfus artışından dolayı kültürel, altyapı, ulaşım, konut ve sosyal gereksinimleri karşılanmasında yerel yönetimler önemli işlemler gerçekleştirmektedir [14]. Özellikle 2000 yılından itibaren belediyelerin şehirlerde artan nüfus yoğunluğu ile sosyal ve çevresel alanlar değişerek insanların artan talep ve ihtiyaçlarına cevap vermekte zorlanmaya başlamıştır [15]. Bilgi ve teknoloji alanındaki gelişmelere paralel belediyelerin bu ihtiyaçlara cevap vermek için yatırımlarının büyük bir kısmını bilişim teknolojilerine yönlendirmektedirler. Artık şehirler tasarlanırken teknolojinin sağladığı çözümlerin merkezine insanı alarak açıklık, sürdürülebilirlik ve katılımcılık esaslarını gözeterek yerel hizmet ve yönetim politikalarının geliştirilmesi ifade edilmektedir. Böylelikle bilgi ve iletişim teknolojilerindeki yenilikçi çözümlerin, kentlerin yönetimine eklenmesi ve kentsel sorunların daha hızlı, etkili ve katılımcı yöntemlerle çözülmesi beklenmektedir. Akıllı şehir kavramı kentlerin çevresel, sosyal ve ekonomik sorunlarını ele alan ve çözümler üretmeye çalışan bir modeldir [16]. Bu model sürdürülebilirlik, yaşam kalitesi, şehirlileşme ve akıllılık olmak üzere dört ayrı kısımda incelenir. Sürdürülebilirlik içerisinde özellikle altyapı, kirlilik, atık, enerji, iklim değişikliği, sosyal konular, ekonomi ve sağlık alt nitelikleri bulunmaktadır. Kentteki insanların duygusal ve mali refahı yaşam kalitesini göstermektedir. Kırsal alanlardan kentsel alanlara dönüşümün teknolojik, ekonomik, alt yapı ve yönetim biçimleri ile şehirleşme niteliğini vurgulamaktadır. Kentlerin ve insanların sosyal, çevresel ve ekonomik kriterlerini iyileştirme arzusu akıllılık olarak tanımlanmaktadır [17]. Akıllı şehir dijital ağları, verimli ve entegre altyapısı ile sürdürülebilir şehir vizyonuna bağlıdır. Giffenger ise “kentlerde yaşam ile beraber insanlar, ekonomi, hareketlilik, çevre, yönetişim ve yaşama alanlarında bilişim teknolojileri katkısıyla ileriye dönük performans gösteren yapıyı, akıllı kent olarak tanımlamaktadır [18].

Akıllı telefonlar, kentte birçok yerine yerleştirilen kameralar, akıllı evler gibi cihazlardan elde edilen veriler sayesinde şehirlerin yaşam kalitesi yükseltilmiş olur. Ücretsiz wifi alanları ile elde edilecek veriler çoğalacak ve ona göre hizmet verilecektir. Akıllı park sistemleri ile park yeri aranmayacağı için zaman ve yakıt harcanmayacağı için çevre kirliliğini önlemiş olmaktadır. Sensörlü sokak lambalarının kullanılması ile enerji tasarrufu yapılmaktadır. Akıllı binalar sayesinde elektrik, su ve enerji tüketiminin kontrol altına alınmaktadır. Akıllı ulaşım sistemleri ile trafik ışıklarında daha fazla beklememek, birbirine entegreli ulaşım sistemleri ile zaman ve maddi tasarruf sağlanmaktadır. Kentin birçok yerine yerleştirilen kameralar sayesinde suç oranlarının

azalmasına ve suçluların daha hızlı bir şekilde bulunması sağlanmaktadır. Şekil 2.1’ de akıllı şehir kavramı gösterilmiştir.



Şekil 2.1. Akıllı şehir kavramı

2.2. Akıllı Şehir Bileşenleri

Akıllı şehirler konusunda yapılan çalışmalarda akıllı şehrin karakteristik özelliklerini oluşturan akıllı şehrin bileşenleri konusunda hemfikir olmuştur. Bu akıllı bileşenler devlet/yönetiminden insana, çevreselden ekonomiye, yaşamsal hayattan ulaşımaya kadar birçok alandan oluşmaktadır [19][20]. Şehrin sosyo-ekonomik, ekolojik, lojistik ve rekabetçi performanslarını geliştirerek, uzun vadede sürdürülebilir performans yaratarak kentler arasında rekabet hedeflenmektedir. Şekil 2.2’ de akıllı şehir bileşenleri verilmiştir.



Şekil 2.2. Akıllı şehir bileşenleri

2.2.1. Akıllı Ekonomi

“Akıllı” olmak, şehre ekonomik canlılık getirir. Kentin mali kaynakları daha iyi kullanılır, hizmet harcamaları azaltılır, yaşam standarttı artmış olur. Konut, yerel kalkınma, ekonomi, kültür, sanat, sosyal politikalar gibi birçok alanda verilen hizmetlerdeki kalite ve nitelik artar. Şehir kaynaklarının verimli kullanılması ve optimize etmeyi amaçlanması kent ekonomisini olumlu yönde etkilemektedir [21]. Teknolojide faydalanılarak ileri üretim, akıllı kümelenmeler, tedarik sistemleri, iş ekosistemleri, verimlilik ve yaşayan laboratuvarlar gibi uygulamalar bu bileşen içerisinde uygulanması gereken değerlendirmelerdir. Yapılan birçok çalışmada büyük şehirlerin sahip oldukları kaynakların daha verimli bir şekilde kullanılmasına izin veren kümelenmiş ekonomileri üreterek daha çok üretkenliğe ve ekonomik büyümeye yol açtığını göstermektedir [22].

2.2.2. Akıllı İnsan

Akıllı şehir uygulamalarının merkezinde insan vardır. Bireylerin kamusal meselelere katılmaları teşvik edilerek fikirlerini ifade etmesi sağlanmalıdır. Böylelikle gerçekleştirilecek uygulamalara insanların katılımı sağlanır. İnsan odaklı yönetimli uygulamalarda kalifiye ve zeki insanların bulunması, insanların yaratıcılık yönü ile farklı ve gelişmiş uygulamalar oluşturulur. Özellikle kent insanların bilgi ve iletişim teknolojileri kullanarak üretme becerilerini arttırarak inovasyonu özendiren topyekûn bütünleştirici bir toplum oluşturulması amaçlanmaktadır [23].

2.2.3. Akıllı Devlet/Yönetim

Günümüzde devlet yönetimlerinin politikası bilişim ve teknoloji odaklı şehirlerin tasarlanıp ve uygulamalarının bulunduğu akıllı şehirlerin oluşturulmasıdır. Sadece politik kararlar değil kurumsal faktörlerle de bunu desteklemesi gerekmektedir. İletişim, liderlik, işbirlikçilik ve veri paylaşımı gibi birçok özellik akıllı kent yönetim modeli için gereklidir [5]. Özellikle kamu kurumları arasındaki dijital işbirliği, karar verme süreçlerinde katılım, yönetim sistemlerinde şeffaflık, kamu hizmetlerinin varlığı ve erişilebilirlik, siyasal stratejilerin kalitesi. Devlet kamu kurum ve kurumları başta olmak üzere sivil toplum kuruluşları gibi topluluklar arasındaki ilişki ve bunların yönetimini kapsamaktadır [24].

2.2.4. Akıllı Ulaşım

Ulaşım çoğu zaman hareketlilikle eşittir. Ulaşımın nesnelerin interneti (IOT) yapısı kullanılarak oluşturulmuş ağların konuşlandırılmasıyla başta çeşitli görev ve uygulamalara göre ele alınması gerekir. Akıllı sokak lambaları, akıllı kavşaklar, toplu taşıma akıllı kart uygulamaları, akıllı bisiklet uygulamaları, akıllı park sistemleri, akıllı trafik sinyalleri, şehir içi navigasyon

uygulamaları gibi şehir ulaşımı ve hareketliliğini daha uygun hale getirerek kaliteli hizmet sunmaktadır.

2.2.5. Akıllı Çevre

Özellikle teknolojiye uygulamalarla çevrenin ve doğanın devamlılığı sağlanarak yeşil alanlar ve su kaynakları kontrol edilmektedir. Şebekeler, yenilenebilir enerji, mikro şebekeler, ileri hava kirliliği izleme sistemleri, sayaçlar, çevre dostu binalar, kent planlaması, su yönetim, sokak aydınlatmaları, katı atık yönetimi, drenaj sistemleri gibi birçok akıllı çözümlerden oluşmaktadır.

2.2.6. Akıllı Yaşam

Akıllı şehirler öğrenen şehirlerdir. IOT teknolojisi kullanılarak insanların iletişimin sağlanmasını, ev ve ofislerini uzaktan erişile yönetebilmesini, çevresiyle daha yakın etkileşime geçmesini sağlamaktadır. Sosyal platform uygulamaların kullanılması ile bireylerin vatandaşın yaşam kalitesini iyileştirmeyi amaçlamaktadır. Mutlu, canlı ve sağlıklı bir yaşama tarzı sağlamaktır [25]. Tablo 2.1’de akıllı şehir bileşenleri verilmiştir.

Tablo 2.1. Akıllı şehir bileşenleri

AKILLI EKONOMİ (Rekabetçilik)	AKILLI İNSAN (Sosyal ve İnsan sermayesi)	AKILLI DEVLET/YÖNETİM (Katılımcılık)
• Yenilikçi ruh • Girişimcilik • Ekonomik imaj ve ticari • Markalar • Üretkenli • Emek piyasasının esnekliği • Dönüştürme yeteneği	• Kalifiye insan kaynağı • Hayat boyu öğrenme • Sosyal ve etnik çoğunluk • Esneklik • Yaratıcılık • Açık görüşlülük • Toplumsal yaşamda katılım	• Katılımcı yönetim • Kamusal ve sosyal hizmetler • Şeffaf yönetim • Politik stratejiler
AKILLI ULAŞIM (Ulaşım ve Bilişim Teknolojisi)	AKILLI ÇEVRE (Doğal Kaynaklar)	AKILLI YAŞAM (Yaşam Kalitesi)
• Bölgesel erişebilirlik • Ulusal ve uluslararası erişebilirlik • BİT altyapısı uygunluğu • Sürdürülebilir, güvenli ve • yenilikçi ulaşım sistemleri	• Doğal koşulların çekiciliği • Kirlilik • Çevre koruma • Sürdürüle	• Kültürel olanaklar • Sağlık koşulları • Bireysel güvenlik • Konut kalitesi • Eğitim faaliyetleri • Turistik çekicilik • Sosyal bütünleşme

2.3. Nesnelerin İnterneti

Kevin Ashton tarafından 1999 yılında ilk defa kullanılan [26]. İngilizcede Internet Of Things (IoT) olan Türkçeye nesnelerin interneti olarak geçen, son yılların gözde teknolojileri arasında yerini almıştır. İnternetin bize sunduğu global ağ ile yaşam hayatımızda kullandığımız birçok nesnenin diğer aygıtlarla iletişim halinde olmasıdır. Aralarında veri transferi yapan ve düşük enerji harcayan heterojen ve otonom IoT cihazlarından bulunmaktadır. Çok sayıda cihazın birbirine bağlanması ve birbirleri arasında veri transferine olanak tanınması ile IoT ağları oluşmaktadır. Nesnelerin interneti kısaca her nesnenin başına ‘akıllı’ kelimesinin getirilmesidir. Telekom, endüstri, sağlık, tarım, lojistik, otomotiv, spor, akıllı enerji, akıllı ev, askeri uygulamalar ve akıllı satış gibi birçok alanlarda kullanılmaları mümkündür. Ayrıca her geçen zamanda farklı alanlarda IoT teknolojileri ve projeleri geliştiren birçok firma kendini göstermektedir. Aslında amaç IoT teknolojilerinin internete bağlı olması gerekir. İnternete bağlanan tüm cihazlar IP adresine ihtiyaç duymaktadır. Günümüz sisteminde kullanılan IPv4 adreslemenin ileride bağlanacak cihaz sayısına yeterli gelmeyeceği durumda IPv6 devreye girmesi ile bu sorunu ortadan kaldıracaktır. Çünkü IPv4 ile 2^{32} adet adresleme kullanılırken IPv6 2^{128} adet adresleme kullanmaktadır. Ayrıca IoT nesnelerinin üretim maliyetlerinin düşmesi ve teknoloji firmaların kendi ürünlerini oluşturmada IoT çeşitliliğini artmasına sebep olmuştur.

Kısaca özetlemek gerekirse IoT teknolojisinin ilerlemesini aşağıdaki teknolojik faktörler verilebilir.

- Sensör, işlemci ve diğer donanımlardaki maliyet düşüşleri,
- Yüksek hızlı ve yaygın internet erişiminin ortaya çıkışı(3G, 4G, 5G),
- Bulut bilişimin yaygınlaşması,
- Mobil devrim ve artan akıllı telefon kullanımı,
- IPV6 Teknolojisi,
- Yapay zekâ teknolojilerindeki ilerlemeler gibi nedenlerden dolayı mümkün kılan gelişmeler yaşanmasına sebep olmuştur.

Ayrıca IoT teknolojileri bize kazandırdığı imkânlar;

- İzleme
- Kontrol Etme
- Optimize Etme ve İyileştirme
- Otonomi


2.4. Büyük Veri

Geleneksel veri tabanı tekniklerinin kullanılması suretiyle işlenmesi mümkün olmayan, farklı boyutlardaki ve türdeki veriyi tanımlayan çeşitli dijital içeriklere büyük veri denir [27].

Bilgi ise belli bir hedefe ulaşmak ya da belirli bir amacı geliştirmek üzere eldeki verinin, bir analiz ve dönüşüm süreci sonucunda insanların ve makinaların anlayacağı faydalı biçime çevrilmiş şeklidir [28]. İnternetin gelişmesi ve sosyal medya kullanımı ile iş yapma şeklini kökten değiştirmiştir. Büyük veriyi niteleyen 7 ana bileşen vardır. Bunlar aşağıdaki şekilde sıralanabilir.

- **Hacim:** Üretilen veri miktarının büyüklüğü terabyte ve daha fazla olması demektir.
- **Hız:** Verinin gerçek zamanlı elde edilme hızıdır.
- **Çeşitlilik:** Elde edilen verinin ses, video, yazı vb. farklı formatlarda olmasıdır.
- **Gerçeklik:** Verinin doğruluğundan emin olmaktır. Büyük veri sürecinde hedefe ulaşabilmek için verinin kirli verilerden arındırılarak temiz tutulmasıdır.
- **Görselleştirme:** Sürekli gelen büyük verinin görselleştirilmesi ve okunabilir hale getirilmesi işlemidir.
- **Değişkenlik:** Verinin değişkenlik durumudur.
- **Değer:** Analiz edilen verinin bir değere dönüştürülmesidir.

Şekil 2.3'te bir araç takip firmasına ait araç bilgilerinin veri piramidi gösterilmektedir. Öncelikle sensörlerle veri elde edilir. Sonra bu veri akıllı cihazlarla bilgiye dönüştürülerek bulut bilişimde depolanır. Bulut bilişimde yapay zekâ kullanılarak analiz edilir. Analiz edilen veri bir değere dönüştürülerek “araç filosu daha nasıl iyi yönetilir?” bilgisine ulaşılır.



Şekil 2.3. Büyük veri değeri piramidi

Artık günümüz özel iş dünyasında firmaların rakiplerine karşı bir adım öne geçip fark yaratmak için minimum bir bilginin bile ne kadar önemli olduğunu kabul etmektedirler. Verileri internet kullanırken yaptığımız tıklamalar, sosyal medya uygulamaları ve sensör teknolojilerinin


dış ortamda aldıkları veriler örnek olarak verilebilir. Elde edilen veriler analiz edilerek değerli bilgiler haline gelmektedir. Şekil 2.4’de IoT yönetim yapısı gösterilmiştir.



Şekil 2.4. IoT yönetim yapısı

Eskiden analiz etmek bu kadar kolay değildi. Örneğin yüksek girişli bir arama motoru hizmeti veren bir firma olduğumuzu düşünelim. Her gün milyonlarca arama ve giriş yapılan bu sistemde elde edilen verilerin klasik yöntemlerle saklanması ve analiz edilmesi mümkün bulunmamaktadır. Özellikle anlık olarak elde edilen verilerin depolanması ve tekrardan o veriye ulaşılması için farklı depolama sistemleri ve erişim yazılımları geliştirilmiştir. Sahip olduğumuz veri çok büyük olduğundan birbiri ile ilişkili olan kelimelerin analizini SQL sorguları ile yapmak mümkün olmamaktadır. Sorgu işlemi o kadar uzun sürer ki elde ettiğimiz bilgi güncelliğini yitirmektedir. Yani klasik yöntemlerle büyük verinin işlenebilmesi pek söz konusu değildir. Büyük veri, ancak büyük veri çözümleri ile işlenebilir. Örnek vermek gerekirse Google klasik yöntemleri bırakarak kendi geliştirdiği teknolojisi ile milyarlarca web sayfasının verilerini Google File System üzerinde, veritabanı olarak Big Table, verileri işlemek için MapReduce kullanmaktadır.

Şekil 2.5’de dünyanın en değerli kaynağı veri olduğu görülmektedir.




Şekil 2.5. Dünyanın en değerli kaynağı veri

“The Economist” dergisinin 2017 yılının mayıs ayında çıkardığı dergi kapağında dünyanın en değerli kaynağının veri olduğu belirtilmiştir [29]. Şirketlerin bu verileri kullanarak rakiplerine karşı yeni rekabet yollarını geliştirerek üstün geleceğini belirtmiştir. İşte büyük veri ile şehirler kontrol edilerek akıllı hale dönüştürülmektedir. Nasıl ki ticari firmalar büyük veri ile rakiplerine fark attıkları gibi kent yöneticileri de bu yolu kullanarak kendi şehirlerini diğer şehirlere göre daha yaşanabilir hale dönüştürebilirler. Bunun çözümü elde edilen büyük veriyi kontrol eden operasyon merkezlerinin kurulması ve bu merkezlerde oluşan veriler analiz edilerek anlamlı hale getirilir. Şehir yöneticileri tarafından analiz edilen bu veriler ışığında her alanda kaynakların tasarruflu kullanılması, güvenli, ulaşım problemi olmayan çağdaş şehirler oluşturulması sağlanmalıdır.

2.5. Bulut Bilişim

Bilişim hizmetlerinde kullanılan veri tabanı, ağ, analiz, yapay zekâ, sunucu ve depolama gibi birçok hizmeti internet ağı vasıtasıyla bulut üzerinden tek merkezi noktasından sağlanması işlemidir. Şekil 2.6’da bulut bilişim yapısı gösterilmiştir.



Şekil 2.6. Bulut bilişim yapısı

Bulut bilişimin bize sağladığı faydalar aşağıda sıralanmıştır:

- Daha hızlı yenilik,
- Kullanılan kaynakların esnetilmesi,
- Kaynakların esnetilmesi ile düşük maliyet.

2.6. Nesnelerin İnternetinin (IoT) Çalışma Prensibi

IoT'ler içinde küçük boyutlarda gömülü elektronik yapılar vardır. Kullanıcı müdahalesi gerek kalmadan otonom şekilde çalışırlar. Bluetooth, RFID, kablosuz sensör ağlar(Wifi) gibi düşük enerji kullanan teknolojilere sahip bu cihazlar, kolayca birbirleri ile bağlantı kurarak, veri aktarımı gerçekleştirmektedirler. Bu cihazlar tarafından elde edilen veriler, bir merkezde toplanır; analiz edilerek alınacak aksiyonlar belirlenir. Gerekirse veriler bulut platformlarında da depolanabilir veya anında işlenebilmektedir. Elde edilen veriler işleme göre anında analiz edilerek sonuca göre diğer cihazlarla iletişime geçilerek gerekli aksiyonlar devreye sokulmaktadır. IoT teknolojisi; mevcut cihazlar arasında hızlı bağlantı kurarak, veri toplayarak ve veri aktarımı yaparak hayatı kolaylaştırmayı hedeflemektedir. Şekil 2.7'de IoT çalışma prensibi gösterilmiştir.



Şekil 2.7. IoT Çalışma Prensipleri

Çok farklı sayıda cihazın kolayca bağlantı kurabilmesi ve aralarında güvenli veri aktarımı yapabilmeleri, yeni geliştirilen IoT platformları ile başarılmaktadır. Bu platformlar, cihazların kolayca ve güvenle birbirleri ile bağlantı kurmasını ve veri aktarmasını sağlayan yazılımlardan oluşmaktadır. IoT platformlar, genellikle erişilebilirliği artırmak açısından “bulut” ortamında çalışmaktadır [30].

2.7. IoT’lerde Güvenlik

IoT cihazları internet bağlı olacakları için siber saldırganların yeni hedefi olacaktır. Birbirine bağlı IoT teknolojisi ile elde edilen verilerin anlık olarak işlenmesiyle insanların günlük yaşantılarından şehir yönetimine, üretim süreçlerinden sağlık hizmetlerine kadar birçok alanda daha önce mümkün olmayan yöntemler gerçekleştirilmektedir. Özellikle çok kritik alanlarda bu sistemdeki güven açıklarının etkisi çok daha büyük olabilmektedir. IoT teknolojileri ile çalışmak isteyen kurumlar iki temel nedenden dolayı güvenlik konusunda zorlanmaktadırlar. Bunların birincisi IoT için kullanılan uç nokta cihazlarının kendilerini koruyamamasıdır. Bu kısım güvenlik konusunda sistemlerin en zayıf noktasını teşkil etmektedir. Saldırganların ağa giriş kısımları buradan olabilmektedir. İkincisi ise ağ ölçeğinin yani ağın çok büyük olmasıdır. Milyarlarca cihazdan bahsedilen bir ortamda ağın her noktasını korumak zor olmaktadır. Bu problemleri çözmek için üretici firmaları farklı yöntemler geliştirmektedirler. Örneğin cisco firması geliştirdiği “Cisco IoT Threat Defense” mimarisi ile ağ güvenli bir şekilde ölçeklenebilir ağlara ayrılarak ağı güvenliği sağlamayı hedeflemiştir. Ayrıca bu mimari içinde ağ davranışlarını tespit eden bulut güvenliği, özel güvenlik duvarı gibi seçeneklerle bu sistemi kurumların hizmetine sunmaktadır. IoT sistemlerde siber saldırı güvenliği için yapay zekâ teknolojilerinden

faaydalanılmaktadır. Ayrıca yapay zekâ ile geliştirilmiş bir makine bu güvenlięi saęlamaktadır. Gnmzde buna rnek vermek gerekirse bankaların kredi kartı güvenlięi iin yapay zekâ kullanılmaktadır. Őekil 2.8’de IoT güvenlięini zetleyen prensipler verilmiřtir.



Őekil 2.8. IoT güvenlięi

2.8. Akıllı Őehir Uygulamaları

Őehirlerin ulařım, park, enerji, güvenlię, evre kirlilięi gibi alanlardaki problemlerini zmek iin yeni teknoloji ve yazılımlarla birok uygulama geliřtirilmektedir. Bu uygulamaların sonucunda maliyet, zaman, iř gc kazanımları ile őehirlerin yařam kalitesini arttıran modern, fonksiyonel ve srdrlebilir gelecekler sunmaktadır.

2.8.1. Akıllı park sistemleri

Őehirlere uzanan yolda klasik otopark sistemlerini inceledięimizde; mevcutta bulunan otopark sistemleri őehirdeki trafik unsurunu arttırmakta, zellikle park yeri aramada geen zaman ve yakıt tketimi ile birlikte havaya salınan karbon gazının evreye zarar vermesini saęlamaktadır. Akıllı otopark sistemi ile klasik otopark sisteminin problemlerine zm retilir. Akıllı otopark sistemleri ile park yeri arama sreleri minimum % 50 oranında kısalırken yakıt tasarrufu ile karbon salınımı byk oranda dřř saęlar. Ayrıca bu sistemleri ile őehir trafięinde duraklamalar azalarak, daha yařanabilir bir őehrin oluřmasına yardımcı olur. Őekilde 2.9’da akıllı park sistemi gsterilmiřtir.



Şekil 2.9. Akıllı park sistemi

Bu sistemler sadece mekânın otomasyona bağlı olan bir otopark sistemi olmamalıdır. Hangi otopark ne kadar doludur? Gideceği hedef noktasına en yakın arabayı park edebileceği nokta neresidir? İlgili otoparka gidebilmek için tercih edeceği güzergâh için trafik durumu nasıldır? Tüm bu soruların cevabını otoparklara yerleştirilen IoT cihazları ile anlık olarak kişilerin ulaşabileceği akıllı otopark sistem uygulamaları geliştirilmektedir. Şehirdeki insanlar cep telefonundan şehrine özel uygulamayı indirerek akıllı şehir ağına hızlı bir şekilde dâhil olabilmelidir.

2.8.2. Akıllı kavşak sistemleri


Şehirlerde bulunan kavşaklar akıllı hale getirilerek; kavşak sinyalizasyon sürelerinin adaptif olarak belirlenmesi, geçiş hakkına sahip araçlara öncelik sağlanması, kavşakların merkezden izlenerek merkezi yönetimi sağlanır. Böylelikle azalan karbon emisyonu ile sürdürülebilir şehirciliğe katkı sağlanır. Kavşak optimizasyonunda kavşaklarda bulunan kameralarla görüntü işleme teknikleri ile anlık araç sayımı yapılarak sinyalizasyon sistemi için veri üretilmesi sağlanır. Şekil 2.10’da akıllı kavşak sistemi gösterilmiştir.



Şekil 2.10. Akıllı kavşak sistemi

2.8.3. Akıllı Durak Sistemleri


Akıllı durak sistemi ile duraktan geçen hatlar, otobüs varış süreleri, sefer iptal gibi bilgiler vatandaşlara paylaşılır. Planlanan sefer sayısı ve güzergâhından sapmalar anlık takip edilir. Otobüs kapasitesinin izlenmesi, hat / otobüs / sürücü planlamalarının yapılması sağlanır. Otobüslerden alınan veriler analiz edilerek araç ve sürüş performansı takip edilir. Durak ve otobüslerde yer alan bilgilendirme ekranlarının yayın yönetimi sistem tarafından uzaktan kontrol edilmesi sağlanır. Şekil 2.11’de akıllı durak sistemi gösterilmiştir.



Şekil 2.11. Akıllı durak sistemi

2.8.4. Akıllı Atık Toplama Sistemi

Çöp konteynerlerinin yerleştirilen IoT sensörleri ile doluluk oranı kontrol edilerek klasik atık toplama sistemi akıllı hale getirilmektedir. Belirli bir atık oranının üzerinde bulunan atık konteynerlerinin boşaltılması için optimize edilmiş, toplama güzergâhının belirlenir. Çöp kamyonlarına iş emri oluşturularak atıkların toplanması ve takip edilmesini sağlanır. Atık konteynerlerinin kontrol ve takibi yapılarak operasyon maliyetleri düşürülür. Atıkların zamanında toplanmasını sağlanarak çöplerin taşma gibi durumlar yaşanmadan halk sağlığı, hijyen ve karbondioksit salınımı açısından oluşan sorunların önüne geçilir. Şekil 2.12’de akıllı atık toplama sistemi gösterilmiştir.



Şekil 2.12. Akıllı atık toplama sistemi

2.8.5. Akıllı Park Sulama Sistemi

Bu sistemlerle parklara yerleştirilen sensör cihazları sayesinde toprağın nem durumu uzaktan merkezi sistem ile takip edilmektedir. Toprağın sulamadan önce hava durumu kontrol edilerek olası yağış durumu doğrultusunda bir sulama planı oluşturulmaktadır. Toprağın ihtiyacı kadar ve uzaktan merkezi olarak yönetilen vanalar aracılığıyla plana uygun olarak sulama yapılır. Bu sistemlerle gereksiz sulamayla toprağın kalite kaybı engellenmekte, su kaynaklarının verimli kullanılması sağlanarak su israfının önüne geçirmektedir. Şekil 2.13’te akıllı sulama sistemi yapısı gösterilmiştir.



Şekil 2.13. Akıllı sulama sistemi

2.8.6. Akıllı Aydınlatma Sistemi

Hava durumu, insan yoğunluğu ve trafik sıklığı durumlarına bakarak halka açık alanlarda bulunan sokak lamba direklerine yerleştirilen sensörlerin ışıklandırma seviyesini ayarlanmaktadır. Buradaki sistem ile enerji tasarrufu yapılarak şehrin ekonomisine katkı sağlanmaktadır. Şekil 2.14’te akıllı aydınlatma sistemi gösterilmiştir.



Şekil 2.14. Akıllı aydınlatma sistemi

Her geçen gün teknolojilerindeki gelişmelerle yukarıdaki uygulamaları çoğaltmak mümkündür.

3. AKILLI KAVŞAK SİSTEMİ

Akıllı kavşak sistemlerinde algılayıcı tabanlı akıllı sistemler öne çıkmaktadır. Bu algılayıcı sistemler arasında manyetik, ultrasonik ve görüntü tabanlı algılayıcılar sayılabilmektedir. Görüntü işleme teknolojisinin taban alındığı çözümler işlevselliği, kolay kurulumu, idamesinin basitliği, verimliliği ve uzun ömürlülüğüyle avantajlıdır. Gerçek zamanlı olarak kamera vasıtasıyla video görüntülerin alınması ve bu görüntülerin işlenmesi neticesinde o andaki yoğunluğa bağlı olarak kavşak ve otoyoldaki trafik akışının yönlendirilmesi en doğru biçimde gerçekleştirilebilmektedir.

Bu tez çalışması kapsamında Malatya Büyükşehir Belediyesi akıllı ulaşım sistemi incelenmiştir. Malatya Büyükşehir Belediyesi'nin Akıllı Ulaşım Sistemleri 2017 yılında 1. Etap çalışmaları tamamlanan ve 19 kavşakta uygulanmaya başlanan Dinamik Kavşak Kontrol Sisteminin 22 kavşağı kapsayan 2. Etap çalışması da 2018 Kasım ayında tamamlanmıştır.

Malatya Belediyesi sorumluluk alanında 74 sinyalize kavşaktan; 42'si dinamik olarak çalıştırılmaktadır. Kalan 14 adet sabit süreli kavşağın da dinamik çalıştırılması için çalışmalar başlatılmıştır. 74 Sinyalize Kavşaktan 59'una Trafik Kontrol Merkezi'nden uzaktan erişim sağlanabilmektedir. Kalan kavşaklar içinse uzak bağlantı ile ilgili altyapı çalışmaları devam etmektedir.

2. Etap çalışmaları kapsamında; 88 adet araç sayım kamerası, 19 adet Hareketli Kamera, 38 adet kamera direği, 20 adet dış ortam ağ anahtarı ve 3 set radyo anten kullanılmaktadır. Dinamik kavşak kontrol sistemi uygulanan kavşaklardaki bekleme sürelerinde ortalama %13 azalma, bu sayede aylık ortalama 25.000 litre yakıt tasarrufu ile 42 ton daha az karbon salınımı sağlanmıştır.

3.1. Dinamik Kavşak Sistemi

Kavşaklardaki sinyalizasyon sistemini araç yoğunluğuna göre değişken süreli olarak yöneten Dinamik Kavşak Kontrol Sistemi, araçların trafikte geçirdikleri zamanı azaltarak akaryakıt tasarrufu sağlayarak çevre kirliliğinin de önüne geçmektedir. Şekil 3.1'de AKS kamera görüntüsü verilmiştir.



Şekil 3.1. Malatya AKS balık gözlü kamera

Kavşaklara yerleştirilen kameralar aracılığı ile yönlerdeki araç yoğunluğunu hesaplayan sistem, kalabalık yönler için daha fazla yeşil ışık süreleri uygulayarak kavşaklardaki gecikme sürelerini azaltmakta, araçların gidecekleri yere daha hızlı ve daha az maliyetle gitmelerine olanak sağlamaktadır. Şekilde 3.2’de Malatya AKS sayım kamera görüntüsü verilmiştir.



Şekil 3.2. Malatya AKS sayım kamerası

3.2. Trafik Kontrol Merkezi

Malatya Büyükşehir Belediye binasında kurulan Trafik Kontrol Merkezi bünyesinde görev yapmakta olan operatörler sayesinde şehrin trafiği 7/24 kontrol altındadır. Kavşaklara bulunan kameralardan elde edilen görüntüler ve kavşak verilerini anlık olarak analiz eden operatörler, hazırladıkları simülasyonlar ile şehrin trafiğini daha iyi yönetmek için tüm olasılıkları değerlendirmekte, ileri ki zamanda meydana gelebilecek tespit edilmeyen durumlar için şimdiden hazırlıklarını tamamlayarak gerekli ön tedbirleri almaktadırlar. Şekil 3.3. AKS kontrol merkezi görüntüsü verilmiştir.



Şekil 3.3. AKS kontrol merkezi

Sistem üzerinde oluşturulan şehir haritası üzerinden tüm sinyalize kavşakların uzaktan takibi ve yönetimi gerçekleştirilmektedir. Sayısal harita tabanlı, kavşaklarla canlı bağlantı kurabilen ve 7/24 iletişim halinde olan, kavşak kontrolünü uzaktan yapabilme becerisine sahip, güncel ve geçmiş trafik verilerine göre istatistiksel analizler yapabilen, çok fonksiyonlu Trafik Kontrol Merkezi Sistemidir.

Şekil 3.4 kavşakların uzaktan takibi ve yönetim yapısı verilmiştir.




Şekil 3.4. Kavşakların Uzaktan Takibi ve Yönetimi

Harita üzerinde yoğun olan alanlar ile sakin alanlar anında görülmektedir. Şekil 3.5'te kavşakların yoğunluk haritaları verilmiştir.



Şekil 3.5. Kavşakların Yoğunluk haritaları

Sistem sayesinde gün içerisinde değişen araç yoğunluklarına uygun ‘‘Sinyal Planları’’ oluşturularak uzaktan anlık olarak kavşaklara yüklenebilmektedir. Şekil 3.6’da kavşak sinyal planları gösterilmiştir.



Şekil 3.6. Kavşak sinyal planları

Araç sayım kameralarının bir diğer avantajı ise ürettiği sayısal veriler ile kavşak ve yol projelerinin planlamasında, sinyal programlarında süre optimizasyonu yapılma noktasında önemli bir yapı oluşturmaktadır. Şekil 3.7’de kavşak araç sayım verileri gösterilmiştir.



Şekil 3.7 Kavşak Araç Sayım Verileri

4. DERİN ÖĞRENME İLE NESNE ALGILAMA

Derin öğrenme, çok katmanlı yapılardan oluşan büyük veri setleri ile sonuçları tahmin eden bir makine öğrenme yöntemidir. Şekil 4.1’de derin öğrenme, makine öğrenmesinin, makine öğrenmesi ise yapay zekânın alt dalı olarak gösterilmiştir.



Şekil 4.1. Derin öğrenme

Derin öğrenme denetimli, yarı denetimli veya denetimsiz gerçekleştirilebilir. Derin öğrenmede çok sayıda veri girişiyle öz nitelikleri kendisi öğrenir. Verinin büyüklüğüne göre öğrenme o kadar başarılı olur. Veriler çok katmanlı yapılarda işlenmektedir. İlk katmanlar daha çok öz nitelik çıkarma katmanlarıdır. Bu tez çalışmasında nesne algılama ve tanıma için evrimsel sinir ağı modelini kullanan YOLO kullanılmıştır.

4.1. Yapay Zekâ

İnsan beyni, yaklaşık yüz milyar nöronu birbirine bağlayan yüz trilyon sinir hücresinden oluşan en karmaşık ve gizemli organdır. Özellikle düşünce, akıl yürütme kavrama, nesneleri algılama ve sonuç çıkarma yeteneklerinin tümü olarak adlandırılan zekânın dijitalleşme isteği bilim insanlarının bu konuda araştırmalar yapmaya sevk etmiştir. İlk olarak Alan Mathison Turing tarafından “Makineler düşünebilir mi?” sorusuyla ortaya atıldı. II. Dünya Savaşı sırasında kriptanalizi ve mesajların deşifre edilmesi gibi ihtiyaçlara yönelik cihazların üretilmesi ile hayata geçirildi [31]. 1956 yılında Dartmouth College’de bu bilim dalının kurucuları olarak kabul edilen M. Minsky, A. Newell ve H. Simon’un katılımıyla gerçekleşen konferans yapay zekânın doğuşu olarak kabul edilmektedir. Ayrıca 1956’da John McCarthy tarafından yapay zekâ terimi ilk defa kullanılmıştır [32]. Bazı eylemleri ya da görevleri yerine getirmek için insan zekâsını taklit eden ve topladıkları bilgilere göre yinelemeli olarak kendilerine kabiliyet sağlayan sistemler

veya makineler anlamına gelir. Günümüzde yapay zekâ alanındaki çalışmaları ile ön planda olan Google firmasının mühendislik müdürü Ray Kurzweil [33] “Yapay Zekâyı ise insanlar tarafından tasarlanan zekâ gerektiren işlevleri yapan makineler yaratma sanatıdır” ifadesi ile yapay zekâyı tanımlamaktadır. Artık hayatımızın tüm alanında yapay zekâ teknolojilerini görmek mümkün olmaktadır.

1997 yılında Deep Blue dünya satranç şampiyonu Kasparov’u yenmesi, 2014 yılında Google tarafından sürücüsüz otomobil prototipinin test sürüşüne çıkarılması, 2011 yılında Apple firması tarafından akıllı telefonlarında yapay zekâ teknolojisi ile ilk kez kişisel asistanı olan Siri’nin IOS işletim sistemli telefonlarında kullanması, Google firmasının ait DeepMind yapay zekâ geliştiricisi firması tarafından 2016 yılında geliştirilen AlphaGo adlı yapay zekânın satrançtan daha karmaşık olan “Go” adlı oyunda dünya şampiyonunu yenmesi ve uzay görevlerinde keşif yapmak 2017 yılından itibaren yapay zekânın teknolojilerinin kullanılması ile hayatımızın her alanında bu bilim dalının görmekteyiz.

Devletler ve teknoloji firmaları yapay zekâ teknolojilerini kullanmak için bu alandaki yatırımlarını her geçen gün arttırmaktadırlar. Gartner’in yayınladığı rapora göre, bu yıl içinde yapay zekâdan elde edilecek olan küresel iş değerinin 1.2 trilyon dolara ulaşması beklenmektedir. Bu değer, geçen yıla göre yüzde 70’lik bir büyüme anlamına gelmektedir. Üstelik yapay zekâ pazarındaki büyümenin bununla sınırlı kalmaması ve 2022 yılında elde edilen gelirin 3.9 trilyon dolara ulaşacağı öngörülmektedir.

Yapay zekânın en çok günümüzde kullanıldığı teknolojiler şunlardır:

1- Doğal Dil Geliştirme: Özellikle müşteri hizmetleri, rapor hazırlama ve iş zekâsı yorumlarında dijital veriden metin üreterek özet oluşturmak amacıyla kullanılmaktadır.

2- Konuşma Algılama: İnsan konuşmasını gerekli formatlara dönüştürerek ilgili yazılımlarının kullanılmasını sağlar. Özellikle interaktif ses tepkisi sistemleri ile mobil uygulamalarda kullanılmaktadır.

3- Sanal Aracılar: Özellikle banka müşteri hizmetleri ve akıllı ev sistemlerinde insanlarla irtibata geçen sistemlerde kullanılmaktadır.

4- Makine Öğrenimi Platformları: Birçok alanda geliştirme ve eğitim araç setleri, algoritma, veri sağlar ve modelleri tasarlamak, API ve uygulamalara, süreçlere ve diğer makinelere dağıtmak için bilgi işlem desteği sunar. Özellikle “sınıflandırma veya tahmin” içeren birçok kurumsal uygulamada kullanılmaktadır.

5- Yapay Zekâ Optimizasyonlu Donanımlar: Yapay zekâ teknolojileri artık çok büyük

verilerle çalışmaktadır. Geliştirilen grafik işleme birimleri (GPU) sayesinde verilerin formüle etme işlemlerini uygun bir şekilde çalıştırmak üzere tasarlanmış ve oluşturulmuştur. Genellikle derin öğrenme uygulamalarına hızlı bir şekilde gerçekleştirilmesini sağlamaktadır.

6- Derin Öğrenme Platformları: Makine öğrenmesinin bir alt dalı olan yapay sinir ağlarından oluşan çok katmanlı özel bir ağ yapısıdır. Özellikle grafik işlem birimleri üzerinde çözemediği örüntü algılamalarında ve çok büyük veri setleri tarafından kullanılan sınıflandırma veya nesne tespit uygulamalarında kullanılmaktadır.

7- Biyometrik: Dokunma algılaması, konuşma ve beden dili gibi çalışma alanlarında insanlar ile makineler arasındaki etkileşimi sağlamak için kullanılan teknolojidir.

9- Robotik Süreç Otomasyonu: İnsan eylemlerini taklit ederek insanların verimsiz ve zorlandıkları alanlarda makinelerin oluşturulmasıdır.

10- Metin Analizi ve NLP: Yapay zekâ teknolojileri bilgisayarlara insan dilini okuma, anlama ve yorumlama yeteneği veren bir yapay zekâ uygulamasıdır.

4.1.1. Makine Öğrenmesi

Bilgisayar ortamında verileri kullanarak matematiksel ve istatistiksel işlemler yaparak tahminlerde bulunan sistemlerin modellenmesidir. Bilgisayar biliminin yapay zekâda alanında 1959 yılında sayısal öğrenme ve model tanıma çalışmalarından geliştirilmiş bir alt dalıdır. Makine öğrenimi algoritmaları gözetimli veya gözetimsiz olarak sınıflandırılmaktadır. Kullanılan algoritmalar eğitim boyunca tahminlerin doğruluğu hakkında geri bildirim sağlarken hem girdi hem de istenen çıktıyı sağlamak için makine öğrenim becerileri ile bir veri bilimcisi veya veri analisti gerekmektedir. Özellikle veri bilimciler eğitilen modelin hangi değişkenleri veya özellikleri analiz edeceğini ve tahminleri geliştirmek için kullanacağını belirlemektedirler. Artık eğitim tamamlandığında, yeni verilerle algoritma öğrenilenleri uygulayacaktır. Şekil 4.1'de makine öğrenmesinin geçmişten günümüze gelişimi gösterilmiştir.



Şekil 4.2. Makine Öğrenmesi

Makine öğrenmesinde algoritmalar üç kısımda incelenir.

► **Gözetimli Öğrenme:** Bu kategoride bulunan algoritmalar öğrenmeyi gerçekleştirmek için etiketli veri kullanırlar. Kullanılacak veri ve veriye ait sınıflar (kategoriler/etiketler) önceden belirlenir. Bu bilgi ile sistem eğitilerek yeni gelen veriyi bu öğrendikleriyle yorumlamaktadır. Bu algoritmaların iyi sonuç vermesi için eğitim verilerinin iyi hazırlanmış olmasına bağlıdır. Öğrenme yöntemi sınıflandırma ve regresyon olmak üzere iki grupta incelenir. Sınıflandırma yöntemleri yapısal veya yapısal olmayan veriler üzerinde çalışır. Regresyonlar ise oluşturulan çıktının devamlı sayısal verilerden oluştuğu mevcut durumlarda kullanılır.

► **Gözetimsiz Öğrenme:** Bu öğrenme modelinde kullanılan veriler gözetimli öğrenme modelinin aksine herhangi bir sınıflandırılmamış ve etiketlenmemişlerdir. Daha önceden eğitilmemiş veriler üzerinde çalışarak bu veriler arasında bağıntılar bulup birbirine yakın anlamda/içerikte/değerde olan verilerin kendi içinde kümelenmesi mantığıyla çalışır. Özellikle kümeleme istatistiksel yaklaşım metodu kullanılır.

► **Yarı Denetimli Öğrenme:** Bu kavram özellikle etiketlenmiş küçük miktarda veri ile etiketlenmemiş büyük miktarda verilerin beraber kullanılması ile gerçekleştirilir.

► **Pekiştirmeli Öğrenme:** Özellikle ağ sayfası sınıflandırma ile genetik sıralama, sınıflandırma

problemlerinde kullanılmaktadır. Pekiştirmeli öğrenme küçük boyutlu etiketlenmiş ve etiketlenmemiş verilerinin birlikte kullanılması ile gözetimli ve gözetimsiz öğrenme arasında yer almaktadır.

4.1.2. Derin Öğrenme

Bir makine öğrenme yöntemidir. Özellikle büyük verilerin işlenmesinde kullanılan bir tekniktir. Bu veriler ses, görüntü veya metin girdilerinden oluşabilir. Günümüzde verinin kolay elde edilmesi sonucunda adını verdiğimiz ‘*Büyük Veri*’ beraberinde hesaplama karmaşıklığı getirmektedir. Aslında burada çok büyük verinin olması değil bu verinin bir değere dönüşmesini sağlanmaktadır. Alexander Thamm’ın dediği gibi “Bizim için büyük veri, küçük veri, hızlı veri ve akıllı veri hepsi sadece veridir.” Verilerin kullanımında kritik başarı adımları hızına, miktarına veya yapısına bağlı değildir. Amaç verilerden bir katma değeri oluşturmak için kullanmaktır. Büyük verileri işlemek için çok hızlı makinalara ihtiyaç vardır. Derin öğrenmede bir modeli eğitmek, büyük miktarda veri kümesi gerektirir. Dolayısıyla bellek açısından büyük hesaplama işlemleri gerekir. Verileri verimli bir şekilde hesaplamak için GPU en uygun seçimdir. Hesaplamalar ne kadar büyükse, GPU’nun CPU’ya göre avantajı o kadar fazladır. Ayrıca derin öğrenmede kullanılan algoritmaların geliştirilmesi ve öznetelik çıkarımının kendi içerisinde yapması başarılı sonuçlarının elde edilmesini sağlamıştır.

Derin öğrenme yapay sinir ağı olan evrişimsel sinir ağı kullanılmaktadır. Buradaki “derin” kısmı, aslında ağı oluşturan katman sayısı demektir. Daha karmaşık problemlerin çözümü için çok sayıda katmana sahip bir ağı ifade etmektedir. Şekil 4.2’ de klasik konvolüsyonel derin öğrenme algoritmalarının çalışma prensibi gösterilmiştir [34].




Şekil 4.3. Klasik konvolüsyonel derin öğrenme algoritmalarının çalışma prensibi

4.2. Evrişimsel Sinir Ağları

ESA bir girdinin görüntüsünü alıp, görüntüdeki çeşitli görüşleri/nesneleri birbirinden ayırabilen derin öğrenme algoritmasıdır. Bu mimaride giriş katmanından alınan görüntü

matrisinin ön işleme adımları ile iyileştirilmesi, özelliklerinin çıkartılması ile elde edilen özniteliklerin tam bağlı katmanlarda sınıflandırılması şeklinde özetlenebilir. Yine bu mimaride de veriyi doğru sınıflandırılmak için makine öğreniminde olduğu gibi eğitim ve test aşamaları bulunmaktadır. Eğitim işleminde en büyük başarıyı elde etmek için eğitim verisi ile her katmanın sahip olduğu ağırlık parametrelerinin belirlenmesi gerçekleştirilmektedir. Daha sonra test aşamasında bu mimarinin sınıflandırma başarısı hesaplanmaktadır.

Aslında temel makine öğrenmesi yöntemleri ile ESA mimarisinin en önemli farklı ESA'da öznitelik modeli çıkarma adımını otomatik olarak yapan evrişim katmanı bulunmaktadır. Bu katmanda giriş verileri üzerinde bir filtreleme işlemi uygulayarak problem için en uygun çıktı değerlerini elde edilmesini sağlamaktır [35]. Şekil 4.3'de evrişimsel sinir ağı mimarisi gösterilmiştir.



Şekil 4.4. Evrişimsel Sinir Ağı Mimarisi

4.2.1 Evrişimsel Sinir Ağı Katmanları

Evrişimsel sinir ağı önizleme katmanı, evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, dropout katmanı, tam bağlı katman ve sınıflandırma katmanlarından oluşmaktadır.

4.2.1.1 Önizleme katmanı

ESA'nın ilk katmanını oluşturmaktadır. Özellik haritasının çıkarıldığı kısımdır. Veri ham olarak bu katmana girdi olarak verilir. Modelin başarımı için verinin çözünürlüğü ve boyutu önemlidir. Şayet görüntü boyutu yüksek seçilirse modelin başarısı artar. Bu işlem sonucunda bellek ihtiyacı ve işlem sayısı artacağından eğitim ve test sürelerinin uzamasına sebep olmaktadır. Sonuç olarak modelin başarısı artabilir. Kullanılacak verilerin boyutu küçük seçildiğinde bellek ihtiyacı azalırken eğitim süresi düşebilir ancak modelin performansıda düşebilir. Modelin başarımı ve eğitim süresi için uygun veri çözünürlüğü belirlemek gerekmektedir. Özellikle renkli imgelerin gri tona dönüştürülmesi, frekansa yoğunluğuna göre sınıflandırma yapılacaksa histogramın çıkarılması, kenar bulma, piksel ekleme gibi işlemler bu katmanda yapılır.


4.2.1.2 Evrişim katmanı

Evrişimsel sinir ağının ana katmanıdır. Öz nitelikler bu katmanda çıkarılır. Klasik makine öğrenmesinde bir arabanın sınıflandırılmasını gerçekleştirmek için öncelikle bir arabanın ayna, tekerlek, sertlik vb. gibi özelliklerinin önceden sisteme belirtilmesi gerekmektedir. Oysaki bir çocuk araba nesnesini ebeveynine arabayı gösterdiğinde onun hiçbir özellik belirtmeden araba olduğunu belirtir. İşte aynı bizlerin öğrenme şeklinin bir modeli olan evrişimsel sinir ağında da nesnelerin öznitelik haritaları bu katmanda belirlenerek öğrenme sağlanır. Bunun için tüm görüntü üzerinde bir filtrenin dolaştırılıp yeni bir matris oluşturulmasıdır. Filtreler kullanılarak kendinden önce gelen görüntüye konvolüsyon işlemi ile bir çıkış verisi oluşturulur. 3x3, 5x5 gibi iki boyutlu filtreler veya 3x3x3, 5x5x3 gibi 3 boyutlu filtreler uygulanır. İmge üzerinde tüm kareler taranacak şekilde filtreler gezdirilir. Filtre katsayıları her karedeki katsayı ile çarpılarak toplanır. Böylelikle yeni bir değer oluşturulur.

Giriş görüntüsü f , çıkış görüntüsü g , evrişim katmanında kaydırılan filtre k , filtrenin bulunduğu piksel konumu (i,j) , ve filtre yatay ve düşey uzunluğu $(2m+1, 2n+1)$ olmak üzere görüntü üzerinde öznitelik çıkarma denklemi Denklem 4.1'de gösterildiği gibidir;

$$g(x,y) = k \times f = \sum_{i=-m}^m \sum_{j=-n}^n k(i,j) \times f(x-i,y-j) \quad (4.1)$$


Şekil 4.4'te görüldüğü gibi 3x3 bir filtre imge üzerinde gezdirildiğinde ortada bulunan pikselin değeri evrişim denklemi uygulandığında yeni değeri elde edilmiş olacaktır.



Şekil 4.5 Evrişim İşleminin Görselleştirilmesi

$$\begin{aligned} g(x,y) &= (-1 * 50) + (-1 * 75) + (-1 * 77) \\ &+ (-2 * 48) + (10 * 70) + (-2 * 83) \\ &+ (-1 * 51) + (-1 * 68) + (-1 * 85) = 32 \end{aligned}$$

İşlem sonucunda pikselin yeni değeri 32 olur. Bu ürün evrişim katmanından sonra filtre boyutlarına bağlı olarak birkaç özellik haritası üretir. Bu şekilde elde edilen haritalar katmanda saklanarak ve ağ filtreleri otomatik olarak öğrenir. Böylelikle görüntüden elde edilen yüksek seviyeli öznitelikler sayesinde yeni bir görüntü elde edilir. Şekil 4.5’de evrişimsel işleminin özellik çıkarımı gösterilmiştir.



Şekil 4.6. Evrişim İşleminin Özellik Çıkarımı

4.2.1.3 Aktivasyon Fonksiyonu Katmanı

Doğrusal olmayan gerçek dünya özelliklerini yapay sinir ağlarını eğitmek için aktivasyon fonksiyonundan faydalanılmaktadır. Bir yapay sinir ağında x girdiler, w ağırlıklar olarak tanımlanır ve ağın çıkışına aktarılan değere $f(x)$ yani aktivasyon işlemi uygulanır. Bu işlemden sonra elden edilen sinyale ağın çıkışı veya bir başka katmanın girişi olacaktır. Eğer bu elde edilen bu sinyali aktivasyon fonksiyonu uygulanmazsa çıkış sinyalimiz bir doğrusal fonksiyon olur. Bu fonksiyonlarda tek dereceli bir fonksiyon olur. Böylelikle ağımız sınırlı öğrenme gücüne sahip bir doğrusal gibi davranır. Bizler ağımızın doğrusal olmayan durumları da öğrenmesini istiyoruz. Bunun sebebi ağımıza video, ses, yazı ve görüntü gibi karmaşık veriler vereceğimiz için bunların anlamlandırılması gerekmektedir [36].

En çok bilenen aktivasyon fonksiyonları şunlardır:

- Basamak fonksiyonu
- Doğrusal fonksiyonu
- Sigmoid fonksiyonu
- Hiperbolik Tanjant fonksiyonu
- ReLU fonksiyonu
- Softmax fonksiyonu

Özellikle yukarıda belirtilen fonksiyonlar içerisinde doğrusal olmayan problemlerin çözümünde Sigmoid, ReLU ve Softmax fonksiyonları kullanılmaktadır. Sigmoid fonksiyonu 0 ile 1 arasında

çıktı üretmektedir. ReLU fonksiyonu ise negatif girdiler için 0 alırken pozitif girdiler için kendisini almaktadır. Softmax fonksiyonu ise çoklu sınıflandırma problemleri için kullanılan bu fonksiyon, verilen her bir girdinin bir sınıfa ait olma olasılığını gösteren 0 ile 1 arası çıktılar üretmektedir.

4.2.1.4 Havuzlama katmanı

ReLU katmanından sonra gerçekleştirilir. Amacı ise bir sonraki katman girişi için girdi boyutlarını yani genişlik ve yükseklik değerlerini küçültmesidir. Tabi ki bu işlem veride derinlik boyutunu etkilememektedir. Gereksiz bilgiler atılarak en önemli bilgiler korunur. Aslında bu işlemin avantajı bir sonraki katman için daha az hesaplama yükü oluşturur ve ağıın ezberlenmesini önlenmiş olur. İmge üzerinde farklı filtreler kullanılarak özneliliklerin elde edilmesi gerçekleştirilir. Filtrelerin belli bir adım atma değerlerine göre gezdirilerek imgedeki piksel değerlerinin maksimum veya ortalaması alınarak işlem gerçekleştirilir. Genellikle maksimum havuzlama kullanılır. konvolüsyon katmanından sonra oluşan görüntülerin hepsi havuzlama katmanından geçirilir [37].

4.2.1.5 Dropout Katmanı

Evrişimsel sinir ağlarında modelin ezberlemesini önlemek için ağdaki belli düğümlerin çıkarılması işlemidir. Bu yapılan işlem ile ağın öğrenmesi sağlanmış olur.

4.2.1.6 Tam bağlı katmanı

Evrişimsel sinir ağlarında konvolüsyon, ReLU ve havuzlama katmanından sonra gelen veriler ağırlandırılarak birleştirilir ve kayıp fonksiyonu sayesinde nöronlara eğitim boyunca verilecek ağırlıklar bulunur. Bu katmanda softmax aktivasyon fonksiyonu kullanılarak olasılıksal sınıflandırma yapılır [38]. Bu katmandan sonra elde edilen çıkış matrisinin satır ve sütun sayıları 1'e eşit olursa tam bağlantılı katman adı verilir.

4.2.1.7 Sınıflandırma Katmanı

Evrişimsel sinir ağlarının son katmanıdır. Ağın sonunda kaç sınıflandırma yapılacaksa o kadar çıkış değeri olmaktadır. Örneğin 15 farklı nesnenin sınıflandırılması yapılacaksa, sınıflandırma katmanı çıkış değeri 15 olmalıdır. Tam bağlantılı katmanda çıkış değeri 4096 olarak seçilirse, bu çıkış değerine göre sınıflandırma katmanı için 4096x15 ağırlık matrisi elde edilecektir. Bu katmanda softmax sınıflandırıcı daha çok kullanılır. Çıkış değerleri 0 ile 1 arasında olur. Çıkış sonucu 1'e yakın olan ağın tahmin ettiği nesne olduğu anlaşılır.

4.2.2. Derin Öğrenme Algoritmaları


Özellikle nesne tanımda kullanılan birçok algoritma bulunmaktadır. Bunlardan YOLO, RetinaNet, R-FCN, SSD algoritmaları zaman ve doğruluk değerleri ile diğer algoritmalarının önüne geçerek tercih edilmeleri sağlamaktadır.

4.2.2.1 YOLO (You Only Looked Once)

Gerçek zamanlı nesne algılama algoritmasıdır. “Sadece bir kez bak” sloganı ile bu alanda başarılı olduğunu belirtmiştir. Geleneksel yöntemlerin aksine nesne tespit etmede nesnenin bulunabileceği muhtemel alanlara ihtiyaç duymamaktadır. Modelin sınıflandırıcı tabanlı sistemlere göre çeşitli avantajları vardır. Test zamanında görüntünün tamamına bakar, böylece tahminleri görüntüdeki küresel bağlam tarafından bilgilendirilir. Ayrıca, R-CNN gibi sistemlerin aksine tek bir ağ değerlendirmesi ile tahminlerde bulunur. Bu R-CNN'den 1000 kat Fast R-CNN'den 100 kat daha hızlı hale getirmiştir.

R-CNN gibi bölge bazlı nesne tespit algoritmaları önce nesne bulunması muhtemel alanları belirleyip ardından oralarda ayrı ayrı ESA sınıflandırıcıları uygulanmaktadır. Bu yöntem her ne kadar iyi sonuçlar verse de bir imge iki ayrı işleme tabi tutulduğu için imge üzerindeki işlem sayısı artmaktadır. Düşük bir FPS (saniye başına kare) almamıza sebep olmaktadır.


Yolo regresyon kullanarak görüntüde bulunan her sınıf için sınırlayıcı koordinatlarını ve olasılıklarını aynı anda oluşturabilmektedir. Her bir sınıf için görüntüde ayrı ayrı işlem yapmak yerine görüntüye yalnızca bir kere bakılır ve tüm sınıflara ait sınırlayıcı kutu koordinatları ve olasılıkları oluşturulur. Bu sayede görüntü üzerinde hangi nesnelerin olduğunu ve nesnelerin görüntünün tam olarak neresinde olduğunu öğrenmek oldukça hızlı bir şekilde gerçekleştirilmektedir. Bu durum geleneksel nesne tespiti yapan sistemlerle karşılaştırıldığında tespit süresini oldukça kısaltmaktadır. Şekil 4.6'da yolo algoritmasının çalışma şekli verilmiştir.



Şekil 4.7. Yolo Algoritmasının Çalışması

4.2.2.2 RetinaNet

İki aşamalı algılayıcıların (Hızlı-RCNN gibi) performansına sahip tek aşamalı bir nesne algılayıcıdır. Özellikle yoğun ve küçük ölçekli nesnelerle iyi sonuçlar üreten nesne algılama modelidir. RetinaNet mevcut tek aşamalı nesne algılama modellerine göre özellikle piramit ağı ve odak kaybı işlemlerinde iyileştirmeler yapılarak oluşturulmuştur. RetinaNet model mimarisi dört kısımdan oluşur. Birinci kısım giriş görüntüsü boyutuna veya omurgaya bakılmaksızın, özellik haritalarını farklı ölçeklerde hesaplayan omurga ağından oluşmaktadır. İkinci bileşen yukarıdan aşağıya doğru yol, daha yüksek piramit seviyelerinden uzamsal kaba unsur haritalarını örnekler ve yanal bağlantılar yukarıdan aşağıya katmanları ve aşağıdan yukarıya katmanları aynı uzamsal boyutla birleştirmektedir. Üçüncü kısım ise her bağlantı kutusu ve nesne sınıfı için her uzamsal konumda bir nesnenin bulunma olasılığını tahmin etmektedir. Dördüncü bileşen her yer gerçek nesne için bağlantı kutularından sınırlayıcı kutuların uzaklığını geri çevirir. Şekil 4.7’de RetinaNet mimarisinin yapısı verilmiştir.




Şekil 4.8. RetinaNet Model Mimarisi

4.2.2.3 R-FCN

Geleneksel bölge teklif ağı (RPN) yaklaşımlarında havuzlama işleminden önce bölge önerileri RPN tarafından üretilir. Daha sonra ROI havuzlama işlemi yapılarak sınıflandırma ve sınırlayıcı kutu regresyonu için tamamen bağlı (FC) katmanlardan geçirilmektedir. Burada ROI havuzlama işleminden sonraki süreç, havuzlama işlemi ile aynı olmamaktadır. FC katmanları bağlantı sayısını artırarak RPN'in yavaşlamasını saplamaktadır.


R-FCN'de ise bölge önerileri almak için hala RPN'lerin olmasına rağmen R-CNN serisinin aksine, ROI havuzundan sonra FC katmanları kaldırılmaktadır. Tüm ana karmaşıklık, ROI havuzundan önce skor haritalarını oluştururken çözülmektedir. Tüm bölge teklifleri, ROI havuzlama işleminden sonra, ortalama değer için aynı puanlama haritalarını basit bir hesaplamayla kullanılmaktadır. Şekil 4.8’de R-FCN mimari yapısı verilmiştir.



Şekil 4.9. R-FCN Mimari Yapısı

4.2.2.4 SSD mobileNet

Nesne tespit işlemini regresyon problemi olarak ele almaktadır [39]. Tek seferde nesne tanımlama işlemi gerçekleştirildiği için düşük donanımlı cihazlarda da sınıflandırma yapabilmektedir. Evrişimsel sinir ağı tek sefer işletildiği için çok hızlı sonuç üretmektedir. Nesne yerlerini belirtilmesi için sınırlayıcı kutu kullanılmaktadır. Girdi olarak alınan görseller matris hücrelere bölünerek farklı özellik haritaları oluşturulmaktadır. Elde edilen özellik haritaları 3X3 filtre yardımıyla sınırlayıcı dikdörtgen kutular elde edilerek nesnelerin algılanması sağlanmaktadır. Eğitim sırasında doğru olan sınırlar ile tahmin sınırları karşılaştırılarak 0.5 değerin üzerindeki sonuçlar pozitif olarak kabul edilmektedir. Nesne tespit işleminde önceliğimiz hız ise SSD modeli tercih edilebilmektedir. Şekil 4.9’da R-FCN mimari yapısı verilmiştir.



Şekil 4.10. R-FCN Mimari Yapısı

4.2.3. Modellerin doğruluk ve zaman karşılaştırılması


Nesne algılamada kullanılan MS COCO Veri Seti kullanılarak 30 FPS'de yolov3 %57,9 mAP'ye sahip olduğu görülmektedir. Tablo 4.1'de derin öğrenme modellerinin ortalama doğruluk ve zaman karşılaştırılması verilmiştir [40].

Tablo 4.1. Derin öğrenme modellerin ortalama doğruluk ve zaman karşılaştırılması

MODELLER	Ortalama Kesinlik değerlerin ortalaması (mAP)	Zaman (time)
SSD321	45.4	61
DSSD321	46.1	85
R-FCN	51.9	85
SSD513	50.4	125
DSSD513	53.3	156
FPN FRCN	59.1	172
RetinaNet-50-500	50.9	73
RetinaNet-101-500	53.1	90
RetinaNet-101-800	57.5	198
YOLOv3-320	51.5	22
YOLOv3-416	55.3	29
YOLOv3-608	57.9	51

5. MATERİYAL VE METOT

Bu tez çalışmasında Malatya Büyükşehir Belediyesi'nden alınan trafik video görüntüleri derin öğrenme modeli kullanılarak araçların tespit ve sayımı gerçekleştirilmiştir. Ardından trafikteki araç yoğunluğuna bakılarak trafik ışıklarının bekleme sürelerinin ayarlanması ile ilgili model geliştirilmiştir. Derin öğrenme ile bir modelin gerçekleştirilmesi için öncelikle veri setinin hazırlanması, eğitimde kullanılacak evrişimsel sinir ağının yapılandırılması ve son olarak model ağırlıklarının elde edilmesi ile sistem oluşturulmuştur.



5.1. Veri Setinin Hazırlanması

Tez çalışması kapsamında Malatya Büyük Şehir Belediyesi Ulaşım Daire Başkanlığı'ndan özel izin alınarak şehrin belli kavşaklarından kamera sistemi ile alınan hareketli trafik videoları alınmıştır. Bu görüntüler belirli işlemlerden geçirilerek görüntüleri meydana getiren resimler her 10 saniyede bir ayrı ayrı resim karelerine dönüştürülmüştür. Toplamda 7200 imgeden oluşan bir veri seti elde edilmiştir. Daha sonra her bir resim kareleri incelenerek kendini tekrar eden ve uygun olmayan görüntüler veri setinden çıkarılmıştır. İşlem sonunda eğitim için yaklaşık 1650 imge kullanılmıştır. Bu imgelerden %80 eğitim için %20 ise test için rastgele bir şekilde ayarlanmıştır. Böylelikle yapay sinir ağı modelinin veri ezberleme hatasının oluşması engellenmeye çalışılmıştır. Şekil 5.1'de kullanılan veri seti örnekleri gösterilmiştir.



Şekil 5.1. Veri seti örneği


Şekil 5.2’de veri setinden çıkarılan uygun olmayan veri örnekleri gösterilmiştir.



Şekil 5.2. Uygun olmayan veri

5.2. Veri Etiketleme

Hazırlanan veriler gözetimli öğrenme yöntemi ile eğitimde kullanabilmek için etiketlenmeleri gerekmektedir. Her bir imgede bulunan “arac” sınıfımıza ait nesne sınırlayıcı kutular ile etiketlenerek imge dosyası ile aynı dosya isminde olan koordinatların tutulduğu txt uzantılı dosya oluşturulmaktadır. Şekil 5.3’de verilerin etiketlenmesi gösterilmiştir.




Şekil 5.3. Veri Etiketleme

Program tarafından her bir imge için .txt dosyası oluşturularak işlem yapılan nesnenin imge üzerindeki koordinatları kullanılan yolov3'ün anlayacağı 0-1 arasında normalize edilerek kaydedilmektedir. Sınıf sayımız "1" olduğu için bu koordinatların başına sınıf indis numarası "0" eklenmektedir. Ayrıca sınıf isimleri ayrı bir classes.txt dosyasında tutulmaktadır.

5.3. Modelin Eğitilmesi

Eğitim için Google Colab tercih edilmiştir. CPU, Tesla K80 GPU ve TPU ile eğitim imkanı verdiği için Google Colab ortamı kullanılmıştır. Eğitim için evrimsel sinir ağı kullanıldığından dolayı GPU ortamı tercih edilmiştir. Eğitime başlamadan önce YOLOV3 için Darknet dosyaları ve önceden eğitilmiş ağırlıklar sisteme yüklenmiştir. Yolov3.cfg dosyasında sırası ile sınıf sayısı 1, filtre sayısı 18, max_batches 2000 steps 1600, 1800 olarak belirlenmiştir. Şekil 5.4'de görüldüğü gibi eğitim 3 saate yakın çalışan sistemde 1400 iterasyon ile sonlanmıştır. Eğitim başında hata oranı 18'lerden 0,69 değerine kadar düşmüştür. Yani eğitimin başından sonuna doğru iyileşmeler görülmüştür. Eğitim sonunda uygun ağırlıklar belirlenmiştir.



Şekil 5.4. Modelin eğitim iterasyon grafiği


Eğitim tamamlandıktan sonra elde edilen ağırlıklar ile veriler edilerek 91.383000 milisaniyede tahmin olayı gerçekleşmiştir. Şekil 5.5’de modelin test edilme süreci gösterilmiştir.



Şekil 5.5. Modelin test edilmesi

Trafik ışığının olduğu kavşak uygulamalarında trafik sinyalizasyon sistemleri sabit ışık süreleri ile oluşmaktadır. Kırmızı ve yeşil ışık süreleri daha önce belirlenerek sabit sürelerde trafik akışı gerçekleşmektedir. Fakat artan araç yoğunluğundan dolayı uygulanan bu sistemde gereksiz bekleme sürelerinden kaynaklanan zaman kaybı, çevre kirliliği ve ekonomik kayıp problemlerin oluşmasını sağlamaktadır. Bu problemleri çözmek için yeni sistemler geliştirilip kullanılmaktadır. Bunlar arasında en iyi çözüm ise görüntü tabanlı akıllı kavşak uygulamasıdır. Bu sistem ile sadece ışık süreleri değil kavşakların görüntülü kontrolleri ve istatistik bilgileri de kayıt altına alınmaktadır. Bu tez çalışmasında test verisi olarak Malatya Büyükşehir Belediyesi tarafından kullanılan akıllı kavşak uygulamasına ait kavşak görüntüleri kullanılmaktadır. Şekil

5.6’da görüldüğü gibi kavşaklardaki araç sayım kameralarından alınan video görüntüleri uygun çözünürlüğe dönüştürülerek oluşturduğumuz sisteme aktarılmıştır. Hazırlanan uygulama ile dört ışıklı bir kavşakta sisteme verilen resimlerle kavşak ışık süreleri resimlerdeki araç sayısına göre dinamik bir şekilde çalıştığı gözlemlenmiştir.



Şekil 5.6. Akıllı kavşak Anamenü

Şekil 5.7’de kavşak görüntü verileri gösterilmiştir.



Şekil 5.7. Malatya Belediyesi kavşak görüntü verileri

Kavşaklarda kırmızı ışıktaki bekleyen araçların sayımını gerçekleştirerek yeşil ışık sürelerinin dinamik olarak belirlenmesi sağlanmaktadır. Araçların sayımını gerçekleştirmek için ise derin öğrenme algoritmalarından faydalanılmaktadır. CSharp programlama dili kullanılarak uygulamamız gerçekleştirilmiştir. Derin öğrenme algoritması olarak Yolov3 algoritması tercih edilmiştir. Projemizde gerçek zamanlı nesne algılama algoritması olan yolov3'ün Aluros.Yolo csharp kütüphanesi kullanılmıştır. Bu kütüphaneyi kullanmak için alturos.yolo 3.06 kütüphanesi projemize referans edilmiştir.

Sistemimiz ilk çalıştığında kavşakta bulunan birinci lamba yeşil ışık ile başlamış ve ışık süresi $t_1=15$ saniye olarak belirlenmiştir. Diğer ikinci, üçüncü ve dördüncü lambaların ışıkları kırmızı olarak atanmış ve ışık süreleri $t_2=200$, $t_3=200$ ve $t_4=200$ olarak atanmıştır. Buradaki amaç birinci lambanın yeşil ışık süresi bitmeden kendinden sonra gelen ikinci lambanın yeşil ışık süresini bu zaman aralığında belirlemektir. Şekil 5.8'de tasarlanan sistem üzerinden kavşaktan görüntünün alınması gösterilmiştir.



Şekil 5.8. Kavşak görüntüsünün alınması

Dinamik kavşak sistemlerde ışık süreleri her duruma göre farklılık gösterdiğinden bekleme veya geçiş süreleri trafik panolarında gösterilmemektedir. Burada birinci ışığın yeşil ışık süresi bizim tarafımızdan belirlenen yedinci saniyeye geldiğinde ikinci ışığın kırmızıda bekleyen araçların resmi kamera ile çekilerek elde edilen görüntü sisteme gönderilmektedir. Sistem tarafından derin öğrenme algoritması kullanılarak nesne tanıma algılaması ile bekleyen araçların sayımı gerçekleştirilmektedir. Şekil 5.9'da tasarlanan sistem üzerinde araçların sayım aşaması gösterilmektedir.



Şekil 5.9. Araçların Sayım aşaması

Şekilde 5.10’da görüldüğü gibi kullanılan derin öğrenme kütüphanesi bir görüntüdeki nesnelerin tipini, genişlik, yükseklik, yatay ve dikey koordinatlarını ve tanıma değerlerini vermektedir.



Şekil 5.10. Nesne algılama

Tablo 5.1’de tespit edilen nesnelerin konum bilgileri, genişlik ve yükseklik gibi özellikleri gösterilmiştir. Bu bilgilere sistem içerisinde ulaşmak mümkün olmaktadır.

Tablo 5.1. Tespit edilen nesnelerin özellikleri

Tipi	Güven Değeri	Yatay Konumu	Dikey Konumu	Genişlik	Yükseklik
Araba	0,563400387763	198	110	96	109
Araba	0,351490288972	179	92	151	182
Araba	0,346583276987	137	72	63	97
Araba	0,28777312324	23	121	93	128
Araba	0,477845072746	189	101	86	91

Aşağıda sözde kodu verilen algoritmanda tespit işlemi yapılmadan önce program içerisinde $k=0$ sayısal bir değişken tanımlanır. Daha sonra tanımlanan her bir nesnenin sınıfı kontrol edilir. Nesnelerin sınıfları araba, otobüs, motor gibi trafik araçları ise k 'nın değeri bir arttırılır. Bu işlem her nesne için tekrarlanır. Böylelikle resimdeki araçların sayımı gerçekleştirilmiş olur.

A1:Başla
A2: k değerini 0 gir
A3: elemanlar kümesindeki elamanı sıra ile aktar
A4: yatay konum x = elamanın X değeri
A5: dikey konum y = elamanın Y değeri
A6: genişlik gen = elamanın uzunluğu değeri
A7: yükseklik $yüksek$ = elamanın yükseklik değeri
A8: sınıfı s = elamanın tipi
A9: dikdörtgen sınıfından dörtgen isimli nesne oluştur ($x,y,genislik,yükseklik$)
A10: yatay konum x = elamanın X değeri
A11: kalem isminde kalem oluştur çizgi kalınlığı =2 ve rengi yeşil
A12: başlangıç noktası (x,y)
A13: dikdörtgen çiz($kalem, dörtgen$)
A14: nesnenin sınıfını ve güven değerini yaz.
A15: eğer sınıf = araba veya otobüs veya motor ise k nın değerini bir arttır
A16: eğer son eleman ise A16 git değilse A2 git
A17: bitir

Tablo 5.2’de ışıklardaki araç sayılarına göre yeşil ışık süreleri verilmiştir.

Tablo 5.2. Araç sayısına göre yeşil ışık süreleri

Araç Sayısı	Yeşil Işık Süresi
Araç sayısı ≥ 0 veya Araç sayısı < 15	15 saniye
Araç sayısı ≥ 15 veya araç sayısı < 25	25 saniye
Araç sayısı ≥ 25	40 saniye

İmgedeki araç sayısı belirlendikten sonra oluşturduğumuz zaman yeşil ışık süresi metoduna bu değer gönderilir. Bu metod içerisinde gelen araç sayısına göre yeşil ışık sürelerinin belirlendiği algoritma ile:

A1: Başla

A2: yesilisiksuresi isimli metod tanımla ve araç sayısı değerini çağır

A3: Eğer araç sayısı ≥ 0 veya araç sayısı < 15 ise 15 değerini ilet ve A6 git.

A4: Eğer araç sayısı ≥ 15 veya araç sayısı < 25 ise 25 değerini ilet ve A6 git.

A5: Eğer araç sayısı ≥ 25 ise 40 değerini ilet ve A6 git.


A6: Bitir

Araç sayısına göre belirlenen ışık süresi İkinci trafik ışığının yeşil ışık süresi belirlenir. Ayrıca bu süre kendisinden sonra gelen üçüncü trafik lambasının kırmızı ışık süresinin belirlenmektedir.




6. BULGULAR VE TARTIŞMA

Şekil 6.1’de görüldüğü gibi klasik makine öğrenmesinde bir görüntüdeki nesneleri tespit işlemlerinde öncelikle her bir nesnenin özellik çıkarımı yapılması gerekmektedir. Çünkü makine öğrenmesinde bir özellik çıkarım yapıldıktan sonra sonuca gidilmektedir. Sonuca bakılarak tekrardan özelliklerin parametreleri değiştirilmektedir. Bu özellik çıkarımı modelin sınıflandırma sonucunu etkilemektedir. Fakat belirlediğimiz parametrelerin iyi bir şekilde optimize edilemediğinden modelin başarı oranında düşük olmaktadır.



Şekil 6.1. Makine öğrenmesi

Şekil 6.2’de görüldüğü gibi öz nitelik çıkarımında derin öğrenme modeline bırakılmıştır. Evrimsel yöntem ile görüntü üzerindeki öz nitelikleri çıkararak bunları yapay sinir ağına sınıflandırma işlemine tabi tutmaktadır. Özellikle hata fonksiyonunda çıkan hataları minimize etmek için ağırlıkların kullandığı parametreleri değiştirirken öz nitelikleri belirlemede kullandığı filtrelerin parametreleride değiştirerek daha iyi optimize ederek iyi sonuçlar almamızı sağlamaktadır. Özellikle günümüzde derin öğrenme algoritmalarının nesne tanımadaki başarı oranı çok iyi durumdadır. Hazırladığımız model ile dört ışıktan oluşan bir kavşakta sisteme verilen resimlerden sistemin araçların tespit ve sayısında büyük oranda doğruluk gösterdiği görülmüştür. Burada özellikle iyi bir kamera sistemi seçilmelidir. Araç sayımında Yeşil ışık süreleri araç sayısına göre anlık olarak belirlenerek hızlı bir trafik akışı sağlanmaktadır. YOLOv3 algoritmasının anlık nesne tespitindeki hızı sayesinde sistem duraksamadan çalışmaktadır.



Şekil 6.2. Derin öğrenme

7. SONUÇLAR

Bu tez çalışmasında akıllı kavşak sistemlerinde kullanılan görüntü işleme tekniği ile trafik ışık sinyalizasyonunun dinamik olarak gerçekleştirilmesinin bir sümülasyonu gerçekleştirilmiştir. Bu sistemde ışıhta bekleyen araçların sayısının tespit edilmesinde derin öğrenme yöntemi kullanılmıştır. Gerçekleştirilen yöntemde oluşturulan veriler yolov3 algoritması üzerinde yapılan eğitimde 0.6924 loss değeri ile öğrenme ağırlıkları oluşturulmuştur. Bu ağırlıklar sistem üzerinde kullanılarak kavşakta ışık sürelerinin statik olarak değil dinamik olarak ayarlanmasını sağlanmaktadır. Bu sistemi oluşturmak için birden fazla yöntem kullanılabilmektedir. Önemli olan maliyet, bakım, kurulum ve performans değerlerini ön planda tutmaktır. Akıllı kavşak sistemlerinde görüntü işleme sistemleri ile hem kurulumu kolay hem de bakımı rahat yapılmaktadır. Kavşakta hangi yolun yoğun olduğu durumu görüldüğünde sadece o yolun ışık süresi müdahale edilerek yeşil ışık süresi arttırılabilmektedir. Bu sistem sayesinde yalnızca ışık sürelerini değil daha birçok işlevi gerçekleştirmede yardım etmektedir. Özellikle şehir içi güvenlik uygulamalarında da kullanılabilecek sistemlerdir. Örneğin çalınan bir aracın bulunması veya aranan bir plakanın takip ve bulunması gibi işlemlerde yine bu sistemlerden faydalanılmaktadır.

KAYNAKLAR

- [1] Deloitte (2016), “Akıllı Şehir Yol Haritası”, E-Makale, <https://www.sehirsizin.com/Documents/Deloitte-Vodafone-Akilli-Sehir-Yol-Haritasi.pdf>, (Erişim Tarihi: 05.12.2017).
- [2] Köseoğlu, Ö.Demirci Y., “Akıllı Şehirler Ve Yerel Sorunların Çözümünde Yenilikçi Teknolojilerin Kullanımı”
- [3] Bilici Z., Babahanoğlu V., “Akıllı Kent Uygulamaları ve Konya Örneği”.
- [4] Herzberg, Caspar (2017), “Akıllı Şehirler Dijital Ülkeler” (Çev. Nadir Özata), İnfoloji-Optimist Yayın Dağıtım, İstanbul.
- [5] Mohamed, Nader, Jameela Al-Jaroodi, Imad Jawhar, Ahmed Idries ve Farhan Mohammed (2018) “Unmanned aerial vehicles applications in future smart cities” Technological Forecasting & Social Change, <https://doi.org/10.1016/j.techfore.2018.05.004>.
- [6] A. Zanella, N. Bui, A. P. Castellani, L. Vangelista, and M. Zorzi, “Internet of things for smart cities,” IEEE Internet of Things Journal, 2014.
- [7] Prashant Jadhav, Pratiksha Kelkar, Kunal Patil, Snehal Thorat “ Smart Traffic Control System Using Image Processing”, International Research Journal of Engineering and Technology, 2016.
- [8] Şenol Pazar, Mehmet Bulut, Cihan Uysal “Yapay Zeka Tabanlı Araç Algılama Sistemi Geliştirilmesi”, Bilim, Teknoloji ve Mühendislik Araştırmaları Dergisi, 2020.
- [9] Ziya Tan, “Derin Öğrenme Yardımıyla Araç Sınıflandırma” 2019.
- [10] Hüseyin Seçkin Dikbayır, Halil İbrahim Bülbül, “Derin öğrenme yöntemleri kullanarak gerçek zamanlı araç tespiti” 2020.
- [11] Abdulsamet Aktaş, “Derin öğrenme yöntemleri ile görüntü işleme uygulamaları”, 2020.
- [12] Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. arXiv preprint arXiv:1905.11946.
- [13] Doç.Dr. Erhan Örselli, Arş. Gör. Selçuk Dinçer, “Akıllı Kentleri Anlamak: Konya ve Barcelona Üzerinden Bir Değerlendirme”.
- [14] Başaran, İ. ve Çiftçi, S. (2011). “Yönetimler arası İşbirliğinin Kentsel Yaşam Kalitesinin Geliştirilmesindeki Önemi”, Afyon Kocatepe Üniversitesi İİBF Dergisi, 13 (2), 251-274.
- [15] Durguter, H. (2012). “Kent Modelleri ve Sürdürülebilir Kent Yönetimi”, International Periodical for the Languages, Literature and History of Turkish or Turkic, 7 (3), 1053-1065.
- [16] Ruhlandt, Robert Wilhelm Siegfried (2018), “The governance of smart cities: A systematic literature review”, Cities, 81, 1-23.
- [17] Ruhlandt, Robert Wilhelm Siegfried (2018), “The governance of smart cities: A systematic literature review”, Cities, 81, 1-23.
- [18] Giffenger, Rudolf (2007), “Smart Cities Ranking Of European Medium-Sized Cities”, Vienna University of Technology Research Report, October, ss.13-18.
- [19] Kim, Tai-hoon, Carlos Ramos ve Sabah Mohammed (2017) “ Smart City and IoT” Future Generation Computer Systems, 76, 159-162.
- [20] Dameri, Renata Paola ,Clara Benevolo ,Eleonora Veglianti ve Yaya Li (2018), “Understanding smart cities as a glocal strategy: A comparison between Italy and China”, Technological Forecasting & Social Change, <https://doi.org/10.1016/j.techfore.2018.07.025>.

- [21] Mohamed, Nader, Jameela Al-Jaroodi, Imad Jawhar, Ahmed Idries ve Farhan Mohammed (2018) “Unmanned aerial vehicles applications in future smart cities” Technological Forecasting & Social Change, <https://doi.org/10.1016/j.techfore.2018.05.004>
- [22] Borsekova, Kamila, Samuel Korónya, Anna Vaňová ve Katarína Vitálišová (2018), “Functionality between the size and indicators of smart cities: A research challenge with policy implications”, Cities 78 (2018) 17–26.
- [23] İstanbul Teknik Üniversitesi Vakfı Yayını Temmuz-Eylül 2017 Sayı 77
- [24] Nam, Taewoo ve Theresa A. Pardo (2011), “Conceptualizing Smart City with Dimensions of Technology, People, and Institutions”, The Proceedings of the 12th Annual International Conference on Digital Government Research.
- [25] Armağan, Volkan (2018), “Dijital Dönüşüm Sürecinde Akıllı Şehirler ve E-Devlet Platformu”, İletişim Kuram ve Araştırma Dergisi, 46.
- [26] Correia, Luis M. ve Wünnel, Klaus (2011), “Smart Cities Applications and Requirements”, Net!Works European Technology Platform, s.9.
- [27] Gahi, Y., Guennoun, M. ve Mouftah, H. T. (2016, 27-30 Haziran). Big Data Analytics: Security and Privacy Challenges. 2016 IEEE Symposium on Computers and Communication (ISCC), Messina, Italy, 952-957.
- [28] Gökçen, H. (2011). Yönetim Bilgi / Bilişim Sistemleri: Analiz ve Tasarım. (2. Baskı).
- [29] <https://www.economist.com/leaders/2017/05/06/the-worlds-most-valuable-resource-is-no-longer-oil-but-data>
- [30] Aşkan, L. (2018). Internet of things (Nesnelerin interneti) nedir? <http://www.teknolo.com/internet-things-nesnelerin-interneti-nedir/>
- [31] Sucu İ., Ataman E., “Dijital Evrenin Yeni Dünyası Olarak Yapay Zeka Ve Üzerine Bir Çalışma”, 2020.
- [32] R. S ve N. P, “Artificial intelligence: A modern approach” Prentice Hall., p. 17, 2009.
- [33] K. R, “The age of intelligent machines” Cambridge, MA: MIT Press., 1992.
- [34] M. Inc, «Introducing Deep Learning with MATLAB,» p. 8, 2017.
- [35] Cengiz A., (2020), “Uydu İmgelerine Derin Öğrenme Tabanlı Süper Çözünürlük Yöntemlerinin Uygulanması Ve İmgelerin İyileştirilmesi”
- [36] Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması | by Ayyüce Kızrak | Medium
- [37] İnik Ö. , Ülker E., (2017), “ Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri”.
- [38] Üzen H., Hanbay K., (2020), “ Yaya özellik tanıma için LM filtre temelli derin evrimsel sinir ağı ”
- [39] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. 2016. Ssd: Single shot multibox detector. Paper presented at the European conference on computer vision.
- [40] Joseph Redmon, Ali Farhadi, “YOLOv3: An Incremental Improvement”, University of Washington.

ÖZGEÇMİŞ

Emrullah EZBERCİ

[illegible]

Government	Percentage
Current government	85%
Previous government	15%

[illegible]

██████████

AKADEMİK FAALİYETLER

Makaleler:

1. II. Uluslararası Bilim ve İnovasyon Kongresi “Akıllı şehirlerde derin öğrenme”, 2021
2. II. Uluslararası Bilim ve İnovasyon Kongresi “Akıllı şehirlerde nesnelerin interneti”, 2021
3. III. Uluslararası Battalgazi Bilimsel Kongresi “Web sitelerinde kimlik avı için denetimli öğrenme algoritmalarının karşılaştırılması”, 2019