




**BANDIRMA
ONYEDİ EYLÜL
ÜNİVERSİTESİ**

AUSUD | **Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi**
JITSA | Journal of Intelligent Transportation System and Applications

Cilt / Volume: 4

Sayı / Issue: 2

Yıl / Year: 2021



e-ISSN 2636-820X

Sahibi
Prof. Dr. Süleyman ÖZDEMİR

Sorumlu Yazı İşleri Müdürü
Prof. Dr. Mehmet TEKTAŞ

Dergi Yöneticisi Editör
Prof. Dr. Mehmet TEKTAŞ

Editörler
Prof. Dr. Mehmet TEKTAŞ
Doç. Dr. Nevzat ONAT
Doç. Dr. Hatice Tülay YAMAN
Dr. Öğr. Üyesi Ufuk ÇELİK
Dr. Öğr. Üyesi Muhammed ARUÇU

Alan Editörleri

Prof. Dr. Serap İNCAZ
Prof. Dr. Yasin ARSLANOĞLU
Prof. Dr. Bülent AKINOĞLU
Doç. Dr. Necla TEKTAŞ
Doç. Dr. İlhan GÖKASAR
Doç. Dr. Abdülhalil YESİL
Dr. Öğr. Üyesi Taylan ENGIN
Dr. Öğr. Üyesi Cemil KÖZKURT
Dr. Öğr. Üyesi Adem DALÇALI
Dr. Öğr. Üyesi Ufuk ÇELİK
Dr. Öğr. Üyesi Hanım ÖZBAY
Dr. Öğr. Üyesi Özgür AKIN
Dr. Öğr. Üyesi Hasan SABİN
Dr. Öğr. Üyesi İlyas ÖZER
Dr. Öğr. Üyesi Mehdi Naci AĞAOĞLU
Öğr. Gör. Abdülhalil ELEN
Öğr. Gör. Ömer İNANF

Yayın ve Dağıtım Kurulu

Prof. Dr. Süleyman ÖZDEMİR (Bandırma Onyedi Eylül Üniversitesi)
Prof. Dr. Alpaslan SEREL (Bandırma Onyedi Eylül Üniversitesi)
Prof. Dr. Feyzullah TEMÜRİTAŞ (Bandırma Onyedi Eylül Üniversitesi)
Prof. Dr. A. Fevzi BABA (Marmara Üniversitesi)
Prof. Dr. Abdulsamet HASILOĞLU (Atatürk Üniversitesi)
Prof. Dr. Erdiğin KÖSE (İstanbul Üniversitesi)
Prof. Dr. Ergun Saat VAROL (İstanbul Üniversitesi)
Prof. Dr. Ferit KAÇAR (İstanbul Üniversitesi)
Prof. Dr. Hasan ERDAL (Marmara Üniversitesi)
Prof. Dr. Mehmet TEKİN (Gaziosmanpaşa Üniversitesi)
Prof. Dr. Mehmet BEKDEMİR (Erzincan Üniversitesi)
Prof. Dr. Öhan Baki ALANKUSLU (Okan Üniversitesi)
Prof. Dr. Rafet BOZDOĞAN (Yalova Üniversitesi)
Prof. Dr. Serap İNCAZ (Nişantaşı Üniversitesi)
Prof. Dr. Servet KILIC (Anadoluhisari Üniversitesi)
Prof. Dr. Bülent AKINOĞLU (ODTÜ) (Türkiye)
Prof. Dr. Mustafa İLİÇLİ (İstanbul Ticaret Üniversitesi) (Türkiye)
Prof. Dr. Serdal TERZİ (Süleyman Demirel Üniversitesi) (Türkiye)
Prof. Dr. Yüksel TAŞDEMİR (Yozgat Bozok Üniversitesi) (Türkiye)
Doç. Dr. Ensoy ÖZ (Yıldız Teknik Üniversitesi) (Türkiye)
Doç. Dr. Hatice Tülay YAMAN (ODTÜ)
Doç. Dr. Müjdat SOYTÜRK (Marmara Üniversitesi)
Doç. Dr. Nevzat ONAT (Manisa Celal Bayar Üniversitesi)
Doç. Dr. Tamer ARSLAN (Bursi Uludağ Üniversitesi) (Türkiye)
Doç. Dr. Abdülhalil YESİL (Bandırma Onyedi Eylül Üniversitesi) (Türkiye)
Doç. Dr. Gülşah BİSMACI (Burdur Mehmet Akif Ersoy Üniversitesi) (Türkiye)
Doç. Dr. İlhan GÖKASAR (Boğaziçi Üniversitesi) (Türkiye)
Doç. Dr. Meseret NALÇAKAN (Eskişehir Teknik Üniversitesi) (Türkiye)
Doç. Dr. Murat ERGÜN (İTÜ) (Türkiye)
Doç. Dr. Necla TEKTAŞ (Bandırma Onyedi Eylül Üniversitesi) (Türkiye)
Doç. Dr. Ufuk ÇELİK (Bandırma Onyedi Eylül Üniversitesi) (Türkiye)
Assoc. Prof. Dr. Viktor HACKER (Graz University of Technology) (Avusturya)
Dr. Öğr. Üyesi Adem DALÇALI (Bandırma Onyedi Eylül Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Aslan COBAN (Sakarya Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Emre DEMİR (Antalya Bilim Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Ethan ÇİLİĞİLİ (Recep Tayyip Erdoğan Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Fatih YONAR (Çankaya Çeşitli Mart Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Ferit YAKAR (Tokat Gaziosmanpaşa Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Gülten KARA (Karadizir Teknik Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Ibrahim AKBEN (Hassan Kalyoncu Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Mehdi Naci AĞAOĞLU (Tokat Gaziosmanpaşa Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Melis ALMULA KARADAYI (İstanbul Medipol Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Metin Mutlu AYDIN (Gümüşhane Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Mithat Şimşek (Tokat Gaziosmanpaşa Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Muhammed ARUÇU (Bandırma Onyedi Eylül Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Murat AY (Yozgat Bozok Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Murat Eray KORKMAZ (Samsun Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Murat İPEK (Sakarya Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Özgür AKIN (Dokuz Eylül Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Onursal CETİN (Bandırma Onyedi Eylül Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Selahattin KÖRÜNALP (Bartın Üniversitesi)
Dr. Öğr. Üyesi Sevgi ATIS (Marmara Üniversitesi)
Dr. Öğr. Üyesi Süreyya KOCABEY (Sağlık Bilimleri Üniversitesi)
Dr. Öğr. Üyesi Şerif DİLEK (Kırıkkale Üniversitesi) (Türkiye)
Dr. Öğr. Üyesi Yasin SARIKAVAK (Yıldırım Beyazıt Üniversitesi)
Dr. Öğr. Üyesi Taylan ENGIN (Bandırma Onyedi Eylül Üniversitesi)
Öğr. Gör. Dr. Cemil OCAK (Gazi Üniversitesi) (Türkiye)
Dr. Lee Young Kyun (Director of ITS Korea) (Kore)
Dr. Evangeles Mısak (Hellenic Institute of Transport) (Yunanistan)
Dr. Ziya ÇAKICI (Bartın Üniversitesi) (Türkiye)
Dr. Ahmet BAĞIŞ (İTÜ)
Dr. A. Önder TÜRKÖĞLÜ (İTÜ)
Dr. Kadir KORKMAZ (TUBİTAK-BİLGEM)
Özcan Hasan TUFAN (Ulaştırma ve Altyapı Bakanlığı) (Türkiye)
Ausder Bşk. Erol YANAR (AUSDER) (Türkiye)
Öğr. Gör. İlhan AKTAŞ (Kırıkkale Üniversitesi) (Türkiye)
Öğr. Gör. Tufan Yılmaz KÜÇÜK (Bilecik Şeyh Edebali Üniversitesi) (Türkiye)
Öğr. Gör. Yusuf AVŞAR (Trakya Üniversitesi) (Türkiye)

Teknik Editör

Ars. Gör. Umut AYDIN (Bandırma Onyedi Eylül Üniversitesi)
Ars. Gör. Caner PENSE (Bandırma Onyedi Eylül Üniversitesi)

Dergi Sekreteryası

Ars. Gör. Umut AYDIN (Bandırma Onyedi Eylül Üniversitesi)
Ars. Gör. Serife Gülşah TAÇ (Bandırma Onyedi Eylül Üniversitesi)

Mizajları

Ars. Gör. Üstün ATAK (Bandırma Onyedi Eylül Üni.)
Ars. Gör. Fatih ERGEZER (Bandırma Onyedi Eylül Üni.)

Ön Kontrol

Ars. Gör. Caner PENSE (Bandırma Onyedi Eylül Üniversitesi)

Bandırma Onyedi Eylül Üniversitesi, Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi (AUSUD) Editörlüğü, 10200, Bandırma/ BALIKESİR

Web: <http://dergipark.gov.tr/jitsa>

Tel: +90 266 717 01 17

Fax: +90 266 717 01 30

E-posta: jitsa@bandirma.edu.tr

Akıllı Ulaşım Sistemleri disiplinler arası bir konu ve uygulamaları sektörler arası olduğundan derginin ismine “Akıllı Ulaşım Sistemleri ve Uygulamaları” dergisi olarak karar verilmiştir. Dergimiz Mühendislik, Teknik Bilimler, Temel Bilimler ve Sosyal Bilimlerin lojistik, ulaşım, haberleşme ve bilişim alanlarını ilgilendiren yapısıyla bilim dünyasına önemli katkı sağlayacaktır.

Dergide, Türkçe ve İngilizce dillerinde makaleler yayımlanmaktadır. Derginin içerdiği konular sayfanın sağ tarafında Konu Başlıkları–Journal Topics sekmesinde verilmiştir. Değerlendirilmek üzere dergimize gönderilen metinlerin, daha önce yayımlanmamış, yayımlanmak üzere kabul edilmemiş ve yayımlanmak için değerlendirilme sürecinde olmaması gerekir. Değerlendirme sürecinde olan ve yayımlanan eserlerin sorumluluğu tümüyle yazar(lar)a aittir. Sayılarımız elektronik olarak yayımlanır. Yayımlanan eserlerin telif hakları Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi'ne aittir. Yayımlanması istenilen çalışmalar dergi yazım kuralları ve yayın ilkelerinde belirtilen koşullara uygun şekilde hazırlanıp gönderilmelidir. Dergiye sunulan makaleler öncelikle şekil ve içerik yönünden ön incelemeye tabi tutulmaktadır. Şekil ve içerik olarak uygun bulunan makaleler hakem tayin edilmek üzere yayın kuruluna sunulmaktadır.

Değerlendirme sürecine geçildikten sonra hakemlik süreci ortalama 3 ile 5 hafta arası sürmektedir. Yayın Kurulu tarafından incelenen makalelere uygun bulunduğu takdirde en az iki hakem atanmaktadır. Hakemlerden gelen raporlar doğrultusunda, makalenin yayımlanmasına, rapor çerçevesinde yazar(lar)dan düzeltme, ek bilgi ve kısaltma istenmesine veya yayımlanmamasına karar verilmektedir. Hakemlerden bir olumlu ve bir olumsuz rapor verilmesi halinde ilgili çalışma Dergi Editörlüğü tarafından uygun görülmesi halinde üçüncü bir hakeme de gönderilmektedir.

Bu Sayının Hakemleri / Referee Board

Dr. Öğr. Üyesi Hasan Bora USLUER (Galatasaray Üniversitesi)

Arş. Gör. Çağlar KARATUĞ (İstanbul Teknik Üniversitesi)

Dr. Öğr. Üyesi Şinasi BİNGÖL (Tokat Gaziosmanpaşa Üniversitesi)

Arş. Gör. Ali SARIKAŞ (Marmara Üniversitesi)

Dr. Öğr. Üyesi Akif KARAFİL (Yalova Üniversitesi)

Dr. Öğr. Üyesi Mehmet Erdi KORKMAZ (Karabük Üniversitesi)

Dr. Öğr. Üyesi Emrullah SONUÇ (Karabük Üniversitesi)

Dr. Öğr. Üyesi Caner ÖZCAN (Karabük Üniversitesi)

Doç. Dr. Mustafa YÜCEL (İnönü Üniversitesi)

Yüksek Mühendis Levent ÖZMEN (MEF Üniversitesi)

Öğr. Gör. Hüseyin BAKIR (Doğuş Üniversitesi)

Arş. Gör. Enes KAYMAZ (Düzce Üniversitesi)

Öğr. Gör. Tufan Volkan KÜÇÜK (Bilecik Şeyh Edebali Üniversitesi)

İÇİNDEKİLER / CONTENTS

- Üniversite yerleşkesi ulaşım planlamasında akıllı ulaşım sistemleri ve teknolojilerinin kullanılması** 99-119
Using intelligent transportation systems and technologies in university campus transportation plan
Mehmet ÜNEŞ, Cemil KÖZKURT
Araştırma makalesi
- Hava taşımacılığında değişen iş modelleri** 120-133
Changing business models in air transportation
Volkan YAVAŞ, Ayla Özhan DEDEOĞLU
Derleme makale
- Smart diagnosis and maintenance systems for railway tracks** 134-147
Demiryolu hatları için akıllı teşhis ve bakım sistemleri
Erdem BALCI, Ertan YALÇIN, Tunay Uzbay YELCE, Niyazi Özgür BEZGİN
Derleme makale
- Different application areas of object detection with deep learning** 148-164
Derin öğrenme tabanlı nesne algılama işlemlerinin farklı uygulama alanları
Sevcan TURAN, Bahar MİLANİ, Feyzullah TEMİRTAŞ
Araştırma makalesi
- Ticari gemilerde operasyonel elektriksel gücün tahmininde makine öğrenmesi yaklaşımı: shaft jeneratörü güç tahmini uygulaması** 165-174
Machine learning approach to estimating operational electrical power on trade vessels: an application for shaft generator power prediction
Tayfun UYANIK
Araştırma makalesi

Elektrikli araç şarj istasyonlarının çok kriterli karar verme yöntemleri ile optimal konumlandırması 175-187

Optimal placement of electric vehicle charging stations with multi-criteria decision-making methods

Melike Sultan KARASU ASNAZ, Beyza ÖZDEMİR

Araştırma makalesi

Araştırma Makalesi

Üniversite yerleşkesi ulaşım planlamasında akıllı ulaşım sistemleri ve teknolojilerinin kullanılması

Mehmet Üneş¹, Cemil Közkurt²

¹ Intelligent Transportation System, Institute of Science, Bandırma Onyedi Eylül University, Bandırma, Turkey

² Intelligent Transportation System, Faculty of Engineering and Natural Sciences, Bandırma Onyedi Eylül University, Bandırma, Turkey

*Correspondence: munes@bandirma.edu.tr

DOI: 10.51513/jitsa.943864

Özet: Teknoloji çağında yaşıyor olmamız her alanda olduğu gibi ulaşım planlanması ve çözümlerinde de kendini sürekli yenileyen bilimsel gelişmeleri kullanmamızı kaçınılmaz hale getirmektedir. Artan insan nüfusu ve şehirlere olan göç sonrasında mevcut ulaşım alt yapıları artık yetersiz gelmektedir. Büyükşehirlerde yönetimler çözüm üretmeye çalışıyor olsa da ön görülemeyen hızlı göç ve kent insanların ihtiyaçlarını karşılayacak yerleşim planlamaları yapılmaması şehir hayatını karmaşaya dönüştürmektedir. Şehir planlaması yapılırken üniversiteler de bu plan içerisinde düşünülerek yapılmalıdır. Ülkemizde, üniversitelerin büyük şehirlerde kurulması ve zamanla gelişmesi bu şehirlere olan nüfus göçünü de beraberinde getirmektedir. Birçok üniversite yerleşkesi dağınık plana sahip olduğu için artık bulunduğu alana sığamaz hale gelmiş ve yeni yerleşke alanları oluşturmaya başlamıştır. Yerleşke alanlarını planlarken, kıymetli olan bu alanların verimli kullanılması gerekmektedir. Yerleşke içi ulaşım ve yerleşkelerin kent merkezleri ile olan ulaşımını akıllı ulaşım sistemleri ve teknolojilerini kullanmak hem zaman verimliliği oluşturacak hem de kıymetli alanların daha iyi şekilde kullanılmasını sağlayacaktır. Bu çalışmada yerleşkelerin bilimsel ve teknolojik gelişime katkısı bağlamında, bünyesinde ve şehirle arasında uygulanan ve uygulanabilecek akıllı ulaşım teknolojileri anlatılarak ya da önerilerek gelecekte ele alınacak yerleşke ulaşım planlamalarındaki akıllı ulaşım sistemlerinin ve teknolojilerinin uygulanmalarına kaynak oluşturmak amaçlanmıştır.

Anahtar Kelimeler: Üniversite, Yerleşke, Akıllı ulaşım

Using intelligent transportation systems and technologies in university campus transportation plan

Abstract: The fact that we live in the age of technology makes it inevitable for us to use constantly renewing scientific developments in transportation planning and solutions. After the increasing human population and migration to cities, the existing transportation infrastructures are no longer sufficient. Although the administrations in the metropolitan areas are trying to find solutions, the unpredictable rapid migration and the lack of settlement plans to meet the needs of the city people turn city life into chaos. While city planning is being done, universities should be made by considering this plan. In our country, the establishment of universities in big cities and their development over time bring population migration to these cities. Since many university campuses have a scattered plan, they can no longer fit into the area they are in and have started to create new campus areas. While planning the campus areas, these valuable areas should be used efficiently. Using smart transportation systems and technologies for intra-campus transportation and transportation between campuses and city centers will both create time efficiency and enable better use of valuable areas. In this study, in the context of the contribution of the campuses to scientific and technological development, it is aimed to create a resource for the applications of smart transportation systems and technologies in the campus transportation plans, which will be discussed in the future by explaining or suggesting the smart transportation technologies that can be applied within the campuses and between the city.

Key words: University, Campus, Intelligent transportation

* Corresponding author.

E-mail address: munes@bandirma.edu.tr

Received 27.05.2021; accepted 16.06.2021

Peer review under responsibility of Bandırma Onyedi Eylül University.

1. Giriş

Akıllı kampüsler akıllı şehirlerin daha küçük ölçekli tasarımı olarak düşünülebilir. Ülkemizde, üniversiteler genellikle şehir merkezleri veya merkeze yakın bölgelerde kurulmaktadır. Akıllı şehirlerde kullanılan birçok uygulama ve teknik akıllı kampüs tasarımında kullanıldığı zaman kampüs içerisinde veya kampüslerin bulunduğu bölge ile daha uyumlu ve sistematik uyum söz konusu olacaktır. Kampüs içerisinde tasarlanan ulaşım ağında akıllı ulaşım tekniklerini kullanarak araçlar ile yayalar arasında oluşacak çakışmaları en aza indirgeyerek mobilite akıcı şekilde sağlanacaktır. Kampüs içerisinde doğal kaynaklar ve yenilenebilir enerji kullanılarak daha çevreci yaşam alanları oluşturulabilir.

1.2. Üniversite ve yerleşkelerin tarihsel gelişimi

Üniversite, Latince “universitas” kelimesinden batı dillerine university olarak geçmiştir. Bizim dilimize Fransızcadan geçen üniversite kelimesi tüm bilgilerin öğretildiği kurum anlamına gelmektedir. İlk üniversiteler Orta Çağ'da birbirinden bağımsız ve ortak yararları olan kişilerin oluşturduğu toplulukları ifade etmektedir (Sönmezler, 2003). Günümüzde üniversiteler, toplumların kültür, bilgi ve gelişmişliklerinin göstergesidir. Üniversiteler sahip oldukları bilgi ve insan birikimiyle toplumun geleceğine yön vermektedir. Üniversiteler günümüzde üç temel işleve sahiptir. Eğitim-öğretim, araştırma-uygulama ve toplum hizmetleri bu üç temel işlevi oluşturmaktadır (Türeyen, 2002). Üniversiteler; bilgi, deneyim ve birikimlerini gelecek nesillere temel işlevi olan eğitim öğretim işlevi ile aktarmaktadır (Karakaş, 1999). Burada bireyler, bilgi ve yetenek yönünden kendilerini hazırlayarak toplum içinde daha donanımlı bir şekilde yerini alırlar. Diğer yönden üniversite, bir araştırmacılar topluluğudur. Çalışmalar bilimsel verilere ve yöntemlere dayandırılarak dünyaya sunulmaktadır (Karakaş, 1999). Üniversiteler kurulma aşamasındayken parçası olacakları kentin mevcut durumu, özellikleri ve gereksinimleri göz önünde bulundurularak planlanmaktadır. Bu nedenle, kentte bir üniversitenin kurulması o kentin fiziksel, sosyal ve ekonomik açıdan gelişmesine ve kalkınmasına yardımcı olacaktır (Özen, 2005). Üniversitelerin, çok eski tarihlerde kurulmuş oldukları bilirse de ilk kurumsal olarak

tanımlanması Orta Çağ'da olduğu kabul edilmektedir. 6. YY'da Hristiyanlık Avrupa'da ortak din olarak kabul edilmesiyle kiliselerin bünyesinde din, felsefe ve hukuk alanında eğitim veren okullar kurulmuştur. Orta çağda okullar tek yapıdan oluşmaktadır. Bu okullar, bilim ve yeni görüşlerden etkilenmemesi amacıyla kiliselerin içerisinde dış dünya ile bağlantısı olmayacak şekilde tasarlanmışlardır. Manastır geleneğinin sürdürüldüğü ve katedral okullarının değişimi sonucunda gelişen üniversiteler, buldukları kentin adını taşımıştır. Böylelikle kentler, üniversitenin tüzüğünü meydana getirmiştir. Şekil 1'de Bologna Üniversitesi (1088) ve Şekil 2'de Paris Üniversiteleri, Avrupa'nın 11. yy.'da kurulan en eski kurumlarıdır (Hashimshony ve Haina, 2005). Bu üniversitelerin günümüz üniversitelerinin ilk örneğini oluşturduğu düşünülmektedir.



Şekil 1. Bologna (1088). (Url-1)



Şekil 2. Paris Üniversiteleri. (Url-2)

İslam kültüründe, ilk eğitim yapıları medreselerdir. Dini ve beşeri ilimlerin öğretildiği medreseler genellikle cami ve külliyesi içerisinde veya yakınında kurulmuştur. Nizamiye Medreseleri, Büyük

Selçuklular zamanında kurulmuş ve vezir Nizamülmülk'ün adıyla anılmaktadır. Medreselerin merkezi ve en büyük olanı, Bağdat'taki Nizamiye Medresesi olup Amul, Basra, Belh, Herat, İsfahan, Musul ve Nişapur'da benzerleri vardı. Şekil 3'teki Bağdat Nizamiye Medreseleri zamanının yükseköğretim kurumları olarak nitelendirilebilir. Diğer medreseler, müderrislerin düzeyine göre orta ya da yükseköğretim sayılmışlardır (Özaydın, 2015).



Şekil 3. Bağdat Nizamiye Medresesi. (Url-3)


Yağıbasan Medresesi, 1157–1158 yılları arasında Nizameddin Yağıbasan tarafından yaptırılmıştır. Tokat'ın Niksar ilçesindeki Niksar Kalesi'nde yaptırılan Yağıbasan Medresesi'nde matematik ve tıp eğitimi verilmiştir. Şekil 4'te gösterilen Yağıbasan Medresesi, Anadolu'nun ilk medresesi olarak bilinmektedir.



Şekil 4. Yağıbasan Medresesi. (Url-4)

Osmanlı İmparatorluğu döneminde ilk medrese 1330 yılında Orhan Bey tarafından İznik'te yaptırılmıştır. Osmanlı İmparatorluğu döneminde eğitime yönelik olarak yapılan bir başka önemli yapı ise bugün Fatih Külliyesi

olarak bilinen Şekil 5'te gösterilen Sahn-ı Seman'dır. 1923 yılında cumhuriyetin ilanından sonra Türk eğitim sisteminde köklü yenilikler uygulanmıştır. 1924 Tevhid-i Tedrisat yasası ile medreseler kapatılmış ve Darülfünun ise İstanbul Darülfünunu adını alarak tüzel kişilik kazanmıştır (Sönmezler, 2003).



Şekil 5. Fatih Külliyesi. (Url-5)

Cumhuriyetin ilk yıllarında kurulan yüksekokullar; Ankara'da Hukuk Mektebi (1925), Gazi Eğitim Enstitüsü (1926), Ziraat Enstitüsü (1930)'dür. 1933 yılında kurulan İstanbul Üniversitesi, ilk Cumhuriyet üniversitesidir. Daha sonra 1944 yılında İstanbul Teknik Üniversitesi, 1946 yılında da Ankara'daki çeşitli mektep, fakülte ve enstitülerin birleştirilmesiyle Ankara Üniversitesi kurulmuştur (Sönmezler, 2003). Türkiye'deki ilk yerleşke tasarımı 1950'li yıllarda yapılmıştır. Yarışma projesi sonucunda uygulanan ilk üniversite ise 1957 yılında kurulan Erzurum'daki Şekil 6'da gösterilen Atatürk Üniversitesi'dir. Üniversite yerleşke alanı içerisinde akademik birimler ve aktiviteler dağınık olarak yerleştirilmiştir.



**Şekil 6. Atatürk Üniversitesi yerleşim planı.
(Url-6)**

1.3. Üniversitelerin nitelikleri ve toplum gelişmesindeki rolü

Üniversitelerin günümüzde sahip oldukları üç temel işlev vardır. Bunlar; Eğitim-öğretim, araştırma-uygulama ve toplum hizmetleridir (Türeyen, 2002). Üniversiteler temel işlevi olan eğitim öğretim işlevi ile bilgi ve deneyim birikimlerini geliştirerek gelecek kuşaklara aktarmaktadır (Meray, 1971 – Karakaş, 1999). Burada birey, bilgi ve yetenek yönünden kendisini hazırlayarak toplum içinde daha donanımlı bir şekilde yerini almaktadır. Diğer yönden üniversite, bir araştırmacılar topluluğudur. Çalışmalar bilimsel verilere ve yöntemlere dayandırılarak dünyaya sunulmaktadır (Karakaş, 1999).

Son olarak toplum hizmetlerini değerlendirirsek; üniversiteler kurulma aşamasındayken parçası olacakları kentin mevcut durumu, özellikleri ve gereksinimleri göz önünde bulundurularak planlanmaktadır. Bu nedenle, kentte bir üniversitenin kurulması o kentin fiziksel, sosyal ve ekonomik açıdan gelişmesine ve kalkınmasına yardımcı olacaktır (Özen, 2005). Diğer yönden, yapılan bilimsel çalışmalar da toplumun gelişmesine hizmet etmektedir.

1.4. Üniversite ve yerleşkelerin buldukları kent ile ilişkisi

Üniversiteler buldukları kente sosyo-kültürel ve ekonomik olarak katkı sağlamaktadır. Üniversiteleri sadece eğitim, öğretim ve araştırma yapan kurumlar olarak değerlendirmek yanlış bir yaklaşımdır. Üniversiteleri toplumdaki uzak bağımsız olarak modellemek imkansızdır. Üniversitelerin kentte bulunan imkanlardan faydalanması, üniversiteye ait tesislerin de o kentte yaşayanlar tarafından kullanılması üniversite ve kent halkı arasında doğrudan bir ilişki kurulmasına neden olmaktadır (Erkman, 1990).

Kentlerde, 20. yy. başlarından itibaren meydana gelen yapısal yoğunlaşma nedeniyle üniversitelerde büyüme ve gelişme sorunları ortaya çıkmıştır. Kent dışında yeni bağımsız yerleşim yerlerinin kurulması ile üniversitelerin yerleşim sorunu çözülmüştür. Amerikan Yerleşke modeli, bütün dünyada benimsenerek günümüze kadar gelmiştir (Sönmezler, 2003).

1.5. Üniversite yerleşkelerinin yer seçimi

Üniversitelerin eğitim ve bilimsel amaçlı işlevleri yerine getirmesinin yanı sıra, bulunduğu kentle olan sosyal, kültürel ve ekonomik ilişkilerinin de önem taşıması nedeniyle üniversite yer seçimi kriterlerinin rasyonel bir yaklaşım ve planlama ile gerçekleştirilmesi özellikle Türkiye gibi kaynakları sınırlı gelişmekte olan bir ülke için büyük önem taşımaktadır (Ünal, 2020). Ülkemizde üniversiteler ilk dönemlerde büyük kentlerde kurulmuştur. Diğer kentlerde kurulan üniversiteler, bölgede bir gelişim aracı olması ve eğitim potansiyelinin canlandırılması amacıyla yola çıkılarak kurulmuştur. (Koroğlu, 1988).

Üniversitelerde uygun arazi seçimi aşamasında ele alınacak olan kriterler:

- Arazinin büyüklüğü ve biçimi (sınırlar, biçim, alan)
- Gelişme olanağı (rezerv alanlar, doğal sınırlar, gelişme maliyet yansıtımı)
- Topoğrafik, jeolojik, jeomorfolojik ve teknik özellikleri (üst zemin, tesviye eğrileri, jeolojik, jeomorfik, hidrojeolojik durum)
- Teknik alt yapı bağlantı (enerji, su, kanalizasyon, telefon)
- Mevcut yapıların durumu ve bağlantıları (yıkılıp,sökülecekler veya muhafaza edilecek yapı, enerji hattı vb.)
- Çevrenin fiziksel etkileri (gürültü, koku, duman, titreşim, çevre kirliliği)
- İlişki ve bağlantılar (kent ilişkisi, esas ikamet bölgesi, araç ve yaya trafiği, tarihi yapılar vb.)
- Görsel karakterleri (manzara, doğal unsurlar, bitkiler vb.)
- İklim etkileri (ısı, rüzgâr, nem, yağış, güneş) (Ersoy, 1981 – Erkman, 1990).

Son olarak, arazinin maliyeti de arazi seçiminde değerlendirilmesi gereken konular arasında yer almaktadır. Arazinin mülkiyet durumu, imar durumu ve hukuki durumu dikkate alınarak fiyat değerlendirilmesi yapılmalıdır. Bunun yanı sıra, arazinin inşaat faaliyetlerine hazırlanması amacıyla ortaya çıkan masrafların

da hesaplanması gerekmektedir. Ancak, Türkiye’de devlet üniversitelerinin sınırlı bütçeye sahip olmaları, üniversite için seçilecek arazinin kamu arazilerinden birinin tahsisi şeklinde çözümlenmesine neden olmaktadır (Erkman, 1990).

1.6. Yerleşke tasarımına bölgenin doğal verilerinin etkisi

Doğru yerleşke tasarımı, bölgenin doğal verileri incelenip değerlendirilmesi yapıldıktan sonra yapılmalıdır. Doğal veriler ve arazi yapısına en uygun plana uygun binalar ile dış mekanlarda istenen işlevsellik sağlanır. Doğal verileri; topoğrafik durum ve iklimsel veriler olarak değerlendirilir.

1.6.1 Topoğrafik durum

Topoğrafik durum, yerleşke alanı arazinin özelliklerine göre şekil alır. Arazi yapısına göre tasarımın değerlendirilmesi yapılır. Arazi yapısı; düz alanlar, konkav(iç bükey) alanlar, konveks(dış bükey)alanlar, vadiler ve sırtlardır. Düz alanlar, arazi düzleminin ufuk çizgisi ile aynı olduğu alanlardır. Kişilerin çok fazla enerji harcamadığı bu alanlar, statik ve yer çekimi ile dengededir. Kullanıcıların kendilerini rahat ve güvende hissettiği bu alanlar, fonksiyonel ve görsel olarak karakteristik özelliğe sahip alanlardır. Yerleşke alanında düz bir arazide yatay ve düşey düzlemde tasarlanan alanlar birbiri ile uyum içerisindedir. Düz alanlarda hareketi kısıtlayan herhangi bir doğal faktör olmaması çeşitli tasarımlar yapmayı mümkün kılar. Spor alanları, otopark ve yapı gruplarının olduğu tasarımların yapılması ve şekillenmesi daha kolay olmaktadır (Booth, 1990). Konveks (dış bükey) alanlar, bir arazide düzlemin yüksek olduğu alanlardır. Doğal çevrede bulunan dağ, tepe gibi alanlar dış bükey alanları göstermektedir. Düz alanlara göre dikkat çekici ve dinamik yapıya sahiptir. Odak noktası olarak görev yapan bu alanlar estetik ve fonksiyonel olarak alanın değer kazanmasını sağlarlar. Konveks alanlar arazide mikro iklimin oluşumuna yardımcı olurlar (Booth, 1990). Sırtlar, dış bükey araziler ile benzer özellik göstermektedir. Vadileri ve diğer alanları birbirinden ayıran bu yapı, çevresinde mikro klima özelliği oluşturmaktadır. Birbiri ile paralel olarak yerleşen mekânların ulaşımında kolaylık sağlarlar (Booth, 1990). Konkav (iç bükey) alanlar, bir hat üzerinde yüzey kayıpları veya iki dış bükey alanın yan yana gelmesi ile

oluşmaktadır. Kullanıcılara kapalı mekân izlenimi vermesiyle kişiler kendilerini bu alanlarda güvenli hissetmelerini sağlarlar (Öner, 1999). Vadiler, iç bükey ve sırt oluşumların özellikleriyle benzer özellik gösterirler. Düşük kotlu alanların oluşturulmasını sağlayan vadiler, çeşitli aktivitelerin konumlandırılmasında önemli rol oynarlar. Teraslama yapılarak oluşturulacak planlama alt yapı ve yerleşim şemasında kolaylık sağlar.

1.6.2 İklimsel veriler

İklimsel veriler, yerleşke mikro iklimi alanın diğer doğal özelliklerinden doğrudan etkilenir. İklimsel koşullar dış ortamda yapılacak planlamada oldukça etkilidir. Örneğin; yerleşke içerisinde tasarlayacağımız yapılar arası bağlantı yolları doğrudan bölgenin iklim yapısı ile ilişkilidir. Yerleşke ulaşımı yaya ve araç için olduğundan iklim koşullarına göre tasarım yapılmaktadır.

1.6.3 Yerleşke yerleşim şemaları

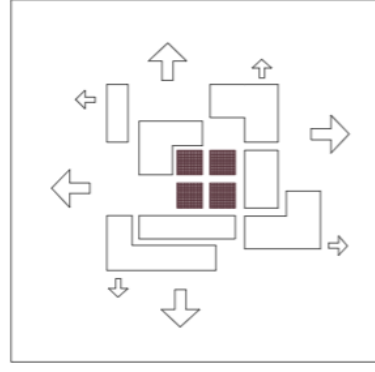
Üniversite yerleşkelerinin kent dışında planlanması oluşacak birçok ihtiyacı kendi içinde çözüm bulunması durumu oluşturmaktadır. Bu yüzden, yerleşke planlamalarında üniversitenin fiziksel gelişimini düzenleyen ve ana işlevler arasında ilişki kuran altı tip yerleşim sistemi geliştirilmiştir.

1.6.3.1 Yaygın yerleşim şeması


Bina yoğunluğunun seyrek olduğu bu sistemde, arazi üzerine binalar dağınık olarak yerleştirilmektedir. Ortak kullanılacak tesisler yerleşkenin merkezinde konumlandırılır, akademik birimler ile bu tesisler arasında boşluk bırakılır. Şekil 7’de bu yerleşim örneği şematik olarak gösterilmiştir. Bina yoğunluğunun düşük olması ve aralıklı yerleştirilmesi birimler arasındaki iletişimin zayıf olmasına, ulaşımın güçleşmesine ve mekânsal bütünlüğün uzun sürede oluşmasına neden olmaktadır. Bu sistem için kent sınırında ya da dışında büyük bir alan gerekmektedir ancak topoğrafya sistem üzerinde etkin bir özellik değildir (Erkman, 1990). Şekil 8’de gösterilen Twente Yüksek Okulu yaygın yerleşim sisteminde tasarlanmış bir yerleşkeye sahiptir.



Şekil 7. Yaygın yerleşim şeması (KSU, 2006).




Şekil 9. Merkezi yerleşim şeması (KSU, 2006).



Şekil 8. Twente Yüksek Okulu planı. (Url-7)

1.6.3.2 Merkezi yerleşim şeması

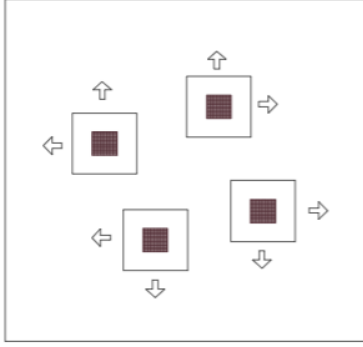
Yoğunluğun yüksek olduğu bir yerleşime sahip olan sistemde, ortak kullanılan birimler merkezden yayılan biçimde akademik birimlerin merkezinde yer almaktadır ve bu durumun bir örneği Şekil 9'da şematik olarak gösterilmiştir. Merkez ile diğer bölümler arasındaki mesafe kısa olduğu için yerleşke içi ulaşım oldukça rahattır. Ancak içe dönük bir yapısı olduğu için çevresi ile bağlantısı zayıftır (Erkman, 1990). Şekil 10'da gösterilen Loughborough Üniversitesi merkezi yerleşim sistemi ile tasarlanmış bir yerleşkeye sahiptir.



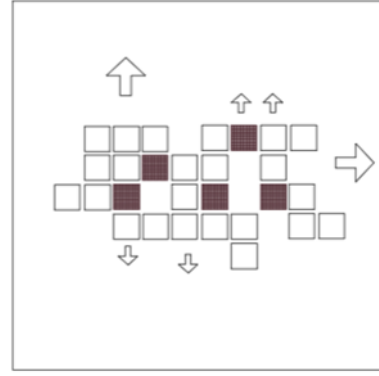
Şekil 10. Loughborough Üniversitesi planı. (Url-8)

1.6.3.3 Moleküler yerleşim şeması

Farklı yapısal ve düzen çekirdeklerinin bir araya gelmesiyle oluşmaktadır. Her çekirdeğin kendine ait ortak kullanım alanları bulunmaktadır ve yüksek yoğunluğa sahiptir. Moleküler yerleşim şeması Şekil 11'de gösterilmiştir. Ancak sistem bir bütün olarak değerlendirildiğinde yoğunluğu etkisini kaybetmektedir. Bu nedenle çekirdekler arasında güçlü bir ulaşım sistemi kurulması gerekmektedir (Erkman, 1990). Şekil 12'de gösterilen San Diego Üniversitesi moleküler yerleşim sistemi ile tasarlanmıştır.



Şekil 11. Moleküler yerleşim şeması (KSU, 2006).



Şekil 13. Şebeke yerleşim şeması (KSU, 2006).



Şekil 12. San Diego Üniversitesi planı. (Url-9)




Şekil 14. Freie Üniversitesi (Url-10)

1.6.3.4 Şebeke yerleşim şeması


Izgara biçiminde oluşturulan sistem, yerleşkede bulunan bütün fonksiyonlar arasında bir bağ kurulmasını sağlamaktadır. Şebeke yerleşim şeması Şekil 13'te gösterilmiştir. Sistemin birbirine bağlı avlulardan meydana gelmesi yüksek yoğunluk oluşturur ve iç ulaşım oldukça kolaydır. Şebeke yerleşim sisteminin kurulabilmesi için engebesiz düz alanlar gerekmektedir (Erkman, 1990). Şekil 14'te gösterilen Freie Üniversitesi şebeke yerleşim sistemi ile tasarlanmıştır.

1.6.3.5 Lineer yerleşim şeması

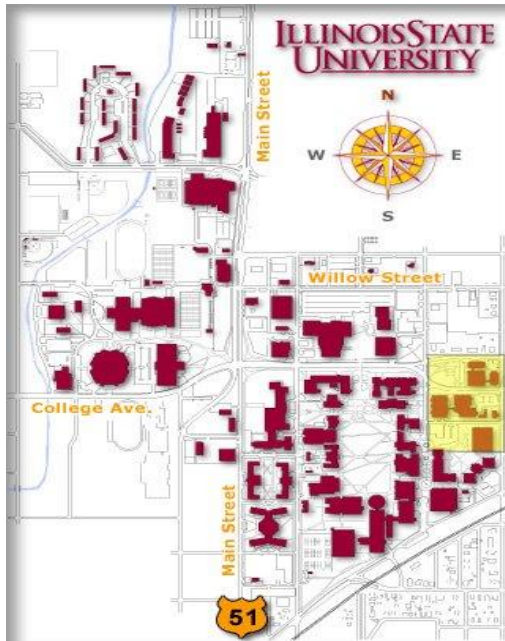
Lineer yerleşim sistemleri, doğrusal bir şerit üzerine yerleştirilmiş ortak kullanılan tesisler ve etrafına oluşturulan diğer fonksiyonel yapılardan oluşmaktadır. Lineer yerleşim şeması Şekil 15'te gösterilmiştir. Merkezden uzaklaştıkça genel kullanımlar özel kullanımlar olmak üzere değişmeye başlamaktadır. Omurga görevini üstlenen bu yerleşim sistemi, yaya-taşıtlı ulaşım sisteminin bir arada tanzim edilmesini sağlamaktadır. Bu yerleşim sistemi, kentin kendi içinde bütünleşmesine ve büyümesine olanak sağlayan bir sistemdir (Erkman, 1990). Şekil 16'da gösterilen Illinois State Üniversitesi lineer yerleşim sistemi ile tasarlanmıştır.



Şekil 15. Linear yerleşim şeması (KSU, 2006).



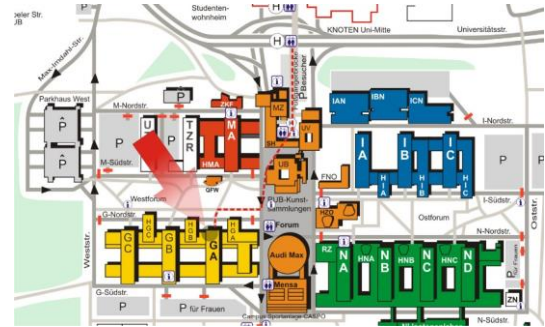
Şekil 17. H tipi yerleşim şeması (KSU, 2006).



Şekil 16. Illinois State Üniversitesi Üniversitesi planı (Url-11)

1.6.3.6 Haç tipi yerleşim şeması

Haç tipi yerleşim sistemlerinde, akademik birimler ve ortak kullanım birimleri bağımsız iki ayrı şerit halindedir. Haç tipi yerleşim şeması Şekil 17'de gösterilmiştir. Birbirlerine dik şekilde yerleştirilen bu şeritler yerleşke merkezinde kesişmektedirler (Türeyen, 2002). Bu yerleşim sisteminde planlanan yerleşke ile kent arasındaki bağlantı, yönü uygun olan bantlardan biri ile sağlanmaktadır. Yaya ulaşımı için uygun bir sistemdir (Türeyen, 2002). Şekil 18'de gösterilen Bochum Üniversitesi yerleşim sistemi H tipi yerleşim sistemi ile tasarlanmıştır.



Şekil 18. Bochum Üniversitesi Üniversitesi planı (Url-12)

2.1. Akıllı ulaşım sistemlerinin tanımı

Akıllı ulaşım sistemlerine kısaca bir tanım yapacak olursak kaba inşaat yol yapımı başlangıcından son kullanıcı olan sürücülerin davranışsal analizlerine kadar bir bütün olarak ortaya konulan elektronik ve bilişim teknolojilerinin kullanıldığı bütüncül bir sistem olarak adlandırılabilir. Günümüz teknolojik gelişmeler ışığında yaşanan nüfus artışı ile ortaya çıkan trafik kaosu beraberinde çözüm üretmesi zorunluluğunu doğurmuştur. Sonuç olarak ekolojik dengenin bozulması zaman ve kaynak israfı toplumların refah seviyesini aşağıya çekmekte yaşam kalitelerini de düşürmektedir. Bu sebeple akıllı ulaşım sistemleri refah seviyesini aşağıya çeken yaşam kalitesini düşüren ulaşım karmaşasını çözmek amacıyla literatürde kendisine yer bulmuştur. Bu sistemlerin modellenmesi ve yenilikçi uygulamalarla entegre edilmesi geleneksel sistemlerde uygulananın aksine, karşımıza etkileşimli bir sistem çıkarmıştır. Akıllı ulaşım sistemi (AUS) olarak adlandırılan bu kavram, hayatımızı iyileştirmek ve taşımayı daha güvenli, daha verimli, konforlu ve ekosisteme

saygı duymak için yenilikçi çözümler sunmaktadır (Maruzen Press, 1997).

2.1.1. AUS'un hayatımızdaki yeri

Dünya genelinde yaşanan teknolojik değişim ve dönüşüm farklı birçok alanda başka amaçlarla kullanılan yeni ürünler ortaya çıkmasına sebep olmuştur. Haberleşme, ulaşım, sağlık ve eğlence gibi insan yaşamının odağında yer alan birçok alanda akıllı kavramı ile kullanılan sistemler bu bağlamda düşünülebilir. Söz konusu yenilikler hayatı kolaylaştırdığı gibi emek tasarrufu da sağlamaktadır (Tufan, 2014). Endüstriyel sahada kullanılan sistemler sıklıkla ulaşım sektöründe karşımıza çıkmaktadır. Ulaşım sektörü içerisinde tercih sebebi olan yeni teknolojik sistemler içerisinde akıllı bilişimi barındırmaktadır, diğer bir deyişle akıllı ulaşım sistemleri olarak hayatımızda yer almaktadır. Günlük yaşam içerisinde her ne kadar yeni bir kavram gibi görünse de esasen altyapısı üzerinde uzunca bir süredir çalışılan alandır. İnsanların günlük ulaşım ihtiyaçlarının giderilmesi noktasında kurgulanan modelde bu sisteme fazlasıyla ihtiyaç duyulmaktadır. Sistem içerisinde mobilitayı sağlamak adına bir başka deyişle bir zekaya duyulan ihtiyaç sahada fiziki denetim yapan insanı çekerek bütün sevk ve idareyi bu sisteme yüklemektedir. Söz konusu akıllı ulaşım sistemleri ile yolcu, taşıt, yol ve koordinasyon merkezi arasında entegrasyon sağlanmaktadır.

2.1.1. AUS'un sağladığı faydalar

Sistemler bireylerin seyahat serbestliğini sağlarken bunun daha güvenilebilir olması için çalışmaktadırlar. Öte yandan mevcut canlı sistem içerisinde sonuçları itibarıyla birçok olumlu çıktısı da bulunan bu model günümüzde trafiğin bir parçası haline gelmiştir.

- Söz konusu sistemlerin kullanılmaya başlanması ile tekil kullanıcıların ödeme noktalarındaki yığılmaları engellenmiştir.
- Yine kamera denetim ve gözetim sistemleri sayesinde kural ihlalleri en aza indirilmiştir.
- Yolcuların seyahat güvenliği sağlanmıştır.
- En önemlisi verimli bir ulaşım sistemi sayesinde enerji tasarrufu sağlandığı gerçeği ülke ekonomisi açısından kayda değer bir yere sahiptir.

Bu sistemlerin yegâne amacı bireylerin seyahat güvenliğini sağlamak, yolcuların konforunu artırmak, yaşanan trafik karmaşasını düşürmek amacıyla iletişim ve bilişim teknolojileri ile interneti birleştirerek ulaşımı daha erişilebilir

hale getirmektedir. Görülmektedir ki bu sistemin faydası birçok alanda karşımıza çıkmaktadır. Hem sürücüler hem de yayalar için genel anlamda bir ihtiyaç haline gelmiştir. Burada sistemin ortaya çıkmasını zorunlu kılan sebeplerden bir tanesi de artan nüfus ve araç sayısıdır (Maruzen Press, 1997).

Akademik yazın da ortaya konulan raporlar ve bilimsel çalışmalar bize göstermektedir ki Paris'te yapılan ilk akıllı ulaşım sistemleri kongresinden sonra dünyanın birçok ülkesi de halihazırdaki trafik kontrol sistemlerini geliştirip iyileştirerek uygulamaya koymuşlardır. Küresel konum paylaşım sistemlerinin yaygınlaşması sonucunda araç içi navigasyon sistemleri ve trafik bilgisi hizmetlerinin sürücülerin kullanımına sunulması ile öngörülebilir ulaşım modelleri hayata geçmiştir. Trafik sıkışık olduğu alanlarda sürücüler tercihlerini farklı güzergahlardan kullanarak zamandan ve yakıttan tasarruf sağlamaktadırlar. Dünya üzerinde bu sistemi en iyi kullanan ülke şüphesiz Japonya'dır. Araç bilgi ve iletişim sistemlerinin yaygın ve etkin kullanımı Japonya'yı dünyanın bu alanda en başarılı operasyonel ülkesi yapmıştır. Küresel ölçekte yaygınlaşan bu sistem nihai olarak yakın gelecekte karşımıza çıkabilecek bir üretim endüstrisi adayıdır. AUS'den elde edilen faydalar ve maliyetler, AUS altyapılarının tüm yaşam döngüsü ve bilginin uygulanmasından dolayı değişken kullanıcı davranışları boyunca çeşitli yönlerden incelenir (Hayashi ve Moriguchi, 2000).



Şekil 19. AUS uygulamalarının tarihsel gelişimi

2.2. 1980 öncesi akıllı ulaşım sistemleri

Akıllı ulaşım sistemleri, özel sektör ve kamu sektörü ile akademik kurumlar arasında iletişim ve yardımlaşmaya dayalı bir perspektif oluşturmuştur. Bu dönemde akıllı ulaşım sistemleri araştırması, yalnızca araç içi navigasyon ve rota rehberlik modülleri üzerine çalışmıştır. Yine bu dönemde

teknoloji fırsat merkezli gelişmiş ve orijinal ekipman üreticisi sayısının da oldukça az olduğu göze çarpmaktadır (Akbaş ve Akdoğan, 2001).

2.2.1. Navigasyon ve Haritalama Teknolojileri

Yakın geçmişte küresel konumlama sistemleri içerisinde yakınlık sinyali olarak da adlandırılan navigasyona ilişkin çalışmalar 1960'lı yılların ortalarına doğru General Motors firmasının sürücü destekli bilgi ve yönlendirme sistemi projesi yine karşımıza çıkmıştır (Bozyer, Alkan ve Fırlalı, 2014). DAIR sistemini kullanan bir otomobil yol koşullarıyla ilgili bilgileri içeren bir servis merkezine acil durum mesajı gönderebilmektedir. Bu sistem sürücünün hareket ettiği güzergâh boyunca yola yerleştirilen (genellikle 3 ila 5 mil arasında) mıknatıslar yardımı ile çalışan konum bilgisi elde etmek amacıyla kullanılan ikili kod sistemini kendisine esas almıştır.

2.2.2. Döngü dedektörleri

Olay algılama sistemlerinde döngü dedektörleri sıklıkla başvurulan sensörlerdir. Bu dedektörler, taşıtın hızını tahmin etmekle kalmayıp sıra, akış ve doluluk oranını da ölçebilmektedir. Endüktif döngü dedektörleri, kaldırımlara monte edilmektedir. Dedektörler kontrol kutusuna bir veya daha fazla tel halkası ile bağlanmaktadır. Araç döngünün üzerinde durduğunda veya geçtiğinde döngünün akım akışındaki değişiklik orada bir aracın var olduğunu işaret etmektedir. Bu döngüler, özellikle trafik ışıklarında bekleyen araçların varlığını tespit etmek ve ışıklarda yer alan trafik kontrol mekanizmasını etkinleştirmek amacı ile kullanılmaktadır ve bu şekilde boş yollar için yeşil ışık bekleme süresini düşürmektedir (U.S.D.T.F H., 2006).

2.2.3. Trafik yönetim merkezleri

İlk trafik yönetimi merkezleri (TYM) 1960'lı yılların sonuna doğru konuşlandırılmışlardır. Birçok otoyol yönetim sisteminin odağında TYM vardır. TYM, otoyol sisteminde hava durumu, araçların hızı, trafik tıkanıklığı gibi bilgileri toplamakta ve sisteme işlemektedir. Söz konusu bu veriler diğer operasyonel ve kontrol verileriyle birleştirilerek son kullanıcı olan kişi ve kurumlar ile paylaşılmaktadır. TYM personeli, otoyolların daha verimli ve efektif biçimde idaresi için bu verileri kullanmaktadır. TYM'ler, trafik ve haber

ağanslarının trafik genel durumu ve olaylara çözüm için cevap arayabilecekleri ve çözümünü koordine edebileceği operasyonel karar alma yerleridir. Bir TYM'nin görevi otoyol ağının ardına geçerek farklı dış paydaşların ve hizmet sağlayıcılarının bir araya getirilmesini sağlayarak bu maksatla teknik kurumsal merkez olarak görev yapmaktadır. Bu kuruluşlar tüm yüzey taşıma sisteminin performansını optimize etmek maksadı ile ortak amaca odaklanmaktadır (Auer, Feese ve Lockwood, 2016).

2.3. 1980 sonrası akıllı ulaşım sistemleri

1980'li yıllarda gelecek on yılda ne gibi büyük değişimlerin yaşanacağına dair sinyaller alınmaya başlanmıştır. Çok uzun süreden beri kullanılan ve uygulanmakta olan sistemlerin artık ihtiyaçları karşılamadığı ve buradan hareketle yeni iletişim ve ulaşım teknolojilerinin üretilmesi ihtiyacı doğduğu gerçeği ile karşı karşıya kalınmıştır. Hava ve çevre düzenine ilişkin kaygılar araç emisyonları ile ilgili birçok düzenlemenin de yapılmasını gerektirmiştir. 1980'li yıllarda bu tür kaygıların merkezinde maliyeti daha az, önceki sürümlere göre daha gelişmiş teknolojiler trafik alanında kullanılmaya başlanmıştır. Algılama iletişim sistemleri kontrol teknolojileri ile birleşerek yeni imkanlar ortaya koymuştur. Ulaşım ve taşımacılıkta yeni otoyolu altyapısı tabanlı teknolojiler ile katma değer yaratacak rekabetçi ortamlar olmuştur. Bu teknolojik gelişim ve dönüşüm sayesinde (sensörler, bilgisayarlar, mikro işlemciler, yeni iletişim teknolojileri ve GPS) ulaşım sistemlerine uygulanmaya başlanmıştır.

2.4. 1990 sonrası akıllı ulaşım sistemleri

Soğuk savaşın 1991 yılında bitmesi ile Berlin Duvarı yıkılmış ve bu ve benzeri birçok gelişme meydana gelmiştir. Sanayi, ulaştırma ve sağlık alanında gözle görülür gelişmeler ortaya çıkmıştır. World Wide Web (www), 12 Mart 1989 yılında hayatımıza girmiştir. www, İnternetin bilgisayarlar, servisler ve ağlar üzerinden birbirleri ile bağlanmalarına izin veren protokoldür. Bu sistem dikkate değer şekilde taşımacılık ve diğer teknik gelişmelerin odağında kullanılmaktadır. Teknolojik gelişmeler, algılama ve hesaplama teknolojilerindeki dönüşüm yardımı ile daha güvenli ve verimli bir ulaşım sistemi amacı ile yeni fırsatlar ortaya çıkmaya başlamıştır. Bu

dilimin en önemli dezavantajı, teknolojideki gelişmenin makro düzeyde taşıma sistemine nasıl uygulayacağı ile ilgili belirsizliktir (Auer, Feese ve Lockwood, 2016).

2.5. 2000 sonrası akıllı ulaşım sistemleri

21. yüzyılın ilk on yılında iletişim ve bilişim teknolojilerinde gözle görülür çok ciddi değişimler ve gelişmeler ortaya çıkmıştır. Kablosuz bağlantı ağlarının sayısı ve kapasitesi artan hızı bu dönemde büyük gelişme göstermiştir. Söz konusu dönemde ortaya çıkan teknolojik gelişmeler teknolojilerin birbiriyle birleşmesi tekil kullanıcıların nihai tüketicilerin mevcut iletişim araçlarına entegre edilen uygulamalar yardımıyla akıllı ulaşım teknolojileri hızla gelişmeye devam etmiştir. Ulaşım ihtiyacı duyan herkesin aşağıdaki verilere ulaşması maksadı ile diğer bir deyişle ulaşım tüketicilerine ihtiyaçları arttıkça operatör ulaşım altyapıları buna cevap vermek maksadıyla yeni sistemleri kendi sistemlerine entegre etmeye çalışmışlardır. Sürücülerin doğru zamanda ve doğru yerde olması maksadıyla yol durumu ve performans bilgilerinin işlenmesi daha da önem kazanmıştır. Kamu geçmişten günümüze bu alanda şüphesiz ilk adımları atmıştır. Devamında özel sektörün bu alanda birtakım yatırımları göze çarpmaktadır. Burada özel sektörün son kullanıcılara kamuya göre daha gerçekçi ve eşzamanlı bilgiler sunduğu bir noktaya gelmiş bulunmaktayız. Kurulan bilgi sistemi ile kullanıcılar tarafından tercih edilen ücretsiz uygulamaların reklam gelirleri ile uygulamanın alt yapısı finanse edilerek daha da gelişmesini sağlamıştır. Örnek olarak, NAVTEQ, kullanıcılarına coğrafi bilgi sistemi verileri ve temel elektronik navigasyon haritaları sunarak karlı bir iş modeli oluşturabilmiştir. Akıllı cep telefonu teknolojisi dünya genelinde çok ileri bir noktaya gelmiştir. Gerçek ve eşzamanlı bilgiye erişimi kolaylaştırmış bu alanda üretilen trafik uygulamalarını akıllı telefonlarda desteklemiştir. Benzer biçimde nihai tüketici olan sistem kullanıcıları sadece içerikten yararlanmak ile kalmayıp aynı zamanda içerik üretme şansına da kavuşmuşlardır. Belli bir lokasyonda meydana gelen trafik sıkışıklığının sebebine ilişkin bildirimde bulunma imkânına kavuşmuşlardır (Peterson, 2014).

2.6. Günümüzde akıllı ulaşım sistemleri

Birçok dışsal faktör akıllı ulaşım sistemi teknolojilerinin gelişimini desteklemiştir. 2000'li yıllarda ortaya çıkan ekonomik krizlerle beraber dünya genelinde birçok ülkede ulaşım altyapı yatırımları ivme kaybetmiştir. Devam eden süreçte mevcut araçlar ve karayolu sistemini sahip olduğu insanların kullanılması ile yetinilmiştir. Bu dönemde büyük yatırımların azalan seyrine rağmen iletişim ve bilgi teknolojilerinde yaşanan hızlı gelişmeler ve büyümeler ilerleyen dönemde büyük yatırımlarla birleşerek kurulacak akıllı ulaşım sistemleri modellerine öncülük etmiştir. Sonuç olarak yukarıda bahsettiğimiz bu faktörler yeni ulaşım ve araştırma girişimlerinin sayısal olarak aniden artmasına sebep olmuştur. Bu da beraberinde kullanıcı dostu arayüz uygulamalar yardımcı olmuştur. Giderek artan, AUS uygulamaları otomatik veya isteğe göre sisteme bağlantılı araçlar olarak değerlendirilmektedir (Auer, Feese ve Lockwood, 2016).

Daha fazla elektronik ve bilişimle donatılan araçlar güvenlik bakımından ileri seviyede gelişme göstermiş direksiyon gaz ve frenin dışında birçok sürücüdenden bağımsız olarak yazılımda kontrol edildiği döneme girilmiştir. Otonom araçlar sensörler yardımıyla araca ait birçok fonksiyonun kontrolünü elinde tutmaktadır. Diğer taraftan araç bilgilerini konumunu diğer araçlara olan mesafesini ve yayalara olan uzaklığını kablosuz teknolojilerle takip etmektedir.

Gelinen noktada araştırmalar, araçların bütün potansiyel faydalarını büyük ölçekli uygulamalarla birleştirerek hayatı kolaylaştırmak ve güvenli hale getirmek bağlamında bize beklenenin ötesinde bir imkan sağlamaktadır (Dopart, 2012). Bu araçlarda sensörler kameralar ve haritalama sistemleri ile beraber birçok özelliğin kullanılması sonucunda sürücünün hiçbir müdahalesi olmadan sürüş güvenliği sağlanmaktadır. Belirlenen 5 adet otomasyon seviyesinde her seviyede araç kullanımı mümkündür (Rouse, 1999),

- 0 (Otonom Olmayan): Sorumluluğun sürücüde olduğu sistemdir. Büyük sorunlar araç beyni tarafından kontrol edilse de bunlar sadece sürücüyü bilgilendirme düzeyindedir.
- 1 (Sürücü Asistanı): Sorumluluğun sürücüde olduğu fakat hız ve direksiyon yönlendirmelerine sürücüye destek olan sistemdir
- 2 (Kısmi Otonom): Sorumluluğun

sürücüde olduğu, ancak bununla beraber aracın çeşitli durumlarda direksiyon ve hızı ile kontrol yetkisinin sürücüdenden alındığı sistemdir. Tesla'nın ürettiği araçlar bu kategoride değerlendirilebilir.

- 3 (Koşullu Otonom): Sorumluluğun araçta olduğu, acil durumlarda müdahale etmek maksadıyla sürücünün sürekli olarak hazırda bulunduğu sistemlerdir. Araç sensörler yardımıyla çevreyi ve yolu algılayarak hızı ve direksiyonu kontrol eder. Bu araçların günümüzde kullanıldığı ülke çok az olmakla birlikte kullanımı henüz yaygın değildir.

- 4 (Yüksek Otonom): Kontrolün tamamen araçta olduğu ve her bir ayrıntının araç tarafından kontrol edildiği sistemlerdir. Acil ve gerekli durumlarda sürücüdenden yardım istenildiği, fakat cevap alınmaması durumunda da çalışmaya devam eden bir sistemdir. Günümüzde test aşamasında olan bu sistemin seri üretimine henüz geçilmemiştir. Konuyla ilgili hukuki prosedür de tam hazır değildir.

- 5 (Tam Otonom): Yapabileceği bütün iş ve işlemleri yapan sürücü yardımına ihtiyaç duymayan henüz prototip aşamasında bulunan bir sistemdir.

Sistemler ve bu sisteme bağlı olarak geliştirilen araçlar öncelikle güvenlik faydalarına yönelmiştir.

Endüstriyel üretim yapan birçok otomotiv ve teknoloji firması otomasyon geliştirme hedefi ile yollarına devam etmektedirler. Google, Mercedes-Benz, Tesla ve Volvo gibi global araç üreticileri kendi tasarımları olan sürücüsüz araçları üretip test etmektedir. Otomobil parçaları tedarikçileri, otonom araçların ihtiyaç duyacağı özel sistemlere olan büyük talebi karşılamak için farklı teknolojiler araştırmakta ve geliştirmektedir (Auer, Feese ve Lockwood, 2016).


Gelişen bu teknolojilere ilave olarak coğrafi konum ve cep telefonlarına entegre edilmiş ticari uygulamalar (Waze ve Uber) akıllı ulaşım sistemleri piyasasını etkilemekte ve daha büyük ölçekte paylaşılan hareketlilik eğilimlerinin ortaya çıkmasını sağlamaktadır. Paylaşılan hareketlilik bilgileri bir otomobilin, yayanın veya bisikletin hızlı ulaşım modlarının ortak kullanılması anlamına gelmekte ve paylaşım ekonomisi ortaya çıkmaktadır. Sonuç olarak kullanıcılar varacakları noktaya ulaşmak maksadı ile araç

sahibi olmak yerine en kısa ve verimli ulaşımı tercih etmektedirler (Auer, Feese ve Lockwood, 2016).

2.7. Türkiye'de akıllı ulaşım sistemlerinin tarihsel gelişimi

Türkiye'de akıllı ulaşım sistemleri ile ilgili hayata geçirilen ilk uygulamalar 1984 yılında İstanbul'un ana arterlerinde bulunan sinyalizasyon sistemlerinin senkronizasyonu diğer bir deyişle birbiriyle işlevselliğinin artırılması şeklinde karşımıza çıkmaktadır (Akbaş ve Akdoğan, 2001). Ardından 1990'lı yıllardan başlayarak ücretlerin elektronik olarak toplandığı bir sisteme geçirmeye başlanmıştır. Devlete ait karayolu ücretlendirme sistemlerinin elektronik ortamda mesafeye bağlı olarak toplandığı bir sistem kullanıcıların hizmetine sunulmuştur (Yardım ve Akyıldız, 2005). 1995 yılından sonra trafiğin daha bir yönetilebilir bir hale gelmesi maksadı ile geliştirilen akıllı bilet uygulamaları yardımı ile sistemlerinde yer alan turnikelerin daha verimli hale gelmesi hedeflenmiştir. Söz konusu uygulama ileriki tarihlerde geliştirilerek kartlı sistemlere evrilmiştir. Bu uygulama başta büyükşehirler olmak üzere ülke genelinde farklı birçok ilde ve ilçede kullanılmaya başlanmıştır. Yine 1995 senesinde İstanbul Büyükşehir Belediyesi bünyesinde kurulan trafik komuta ve kontrol merkezi vasıtası ile 160 kritik kavşak birbirine entegre edilerek sinyalizasyon kontrolü sağlanmış ve trafik akışı ile ilgili bilgiler son kullanıcılara sunulmaya başlanmıştır. 1999 senesinde Bolu ili sınırlarında yer alan Bolu dağı geçişini daha etkin hale getirmek maksadı ile Yol Trafik Bilgilendirme Sistemi kurulmuştur. Radyo frekansı ile tanımlama teknolojisi kullanarak yolculara yol ve hava durumu ile ilgili veri akışı sağlanmaya başlanmıştır. 2000'li yıllardan itibaren yol ve köprü geçişlerini otomatikleştirmek ve trafik yoğunluğunu azaltmak amacı ile Otomatik Geçiş Sistemi (OGS), Kartlı Geçiş Sistemi (KGS) ve Hızlı Geçiş Sistemi (HGS) gibi uygulamalar geliştirilmiş ve kullanımı yaygınlaştırılmıştır. (Yalçın ve Büyük, 2015).

2001 yılının ardından yolcuları eşzamanlı olarak bilgilendirmek maksadı ile Karayolları Genel Müdürlüğü tarafından yollara konumlandırılan mesaj panoları ve işaretleri yardımı ile ulaşım sisteminde başka evreye geçilmiştir. 2001 senesinde Ankara'da



Şekil 20. Otonom sürüş seviyeleri

kullanılmaya başlanılan akıllı manyetik kartlar elektronik ödeme sistemini hayatımıza katmıştır. 2006 senesinde İstanbul Büyükşehir Belediyesi ile Emniyet Genel Müdürlüğü'nün ortak projesi olan elektronik denetleme sistemleri uygulanmaya başlanmıştır. 2005-2010 yılları arasında Karayolları Genel Müdürlüğü'nce 144 tane otomatik araç sayım istasyonu konumlandırılmıştır. 2010 yılı bu konuda birçok yeniliğin karşımıza çıktığı bir dönem olmuştur. Birçok şehirde hayata geçirilen akıllı duraklar yolcu bilgilendirme sistemleri bireylerin hayatlarını ciddi anlamda kolaylaştırmıştır. Yolculara sefer ve güzergah saatleri, alternatif ulaşım bilgileri ve benzeri birçok alanda eş zamanlı bilgiler sunan bu sistemler (MOBİETT, EGO Cepte vb.) mobil cihazlarla entegre edildiklerinde ne kadar faydalı oldukları ortaya çıkmaktadır. Tekil kullanıcıların faydasını bile gözeterek hayatına kolaylık sağlayan uygulamalar, kullanılmadığı durumlarda sistemin ne kadar gerekli olduğu gerçeği ile bizi karşı karşıya bırakmaktadır. Birçok bilgi, kullanıcıya gerçek zamanlı olarak ve yüksek doğrulukla verilmeye başlanmıştır (Dopart, 2012).

3. Yerleşke ulaşım ağının tasarlanması

Yerleşke içerisinde bulunan mekanlar arasında ve yerleşke ile bağlı bulunduğu kente ulaşım yaya, bisiklet veya motorlu taşıtlar aracılığıyla sağlanabilir. Genellikle yerleşke içerisinde ulaşım yaya olarak sağlanması hedeflenir. Fakat yerleşkenin büyüklüğü ve bölgenin iklim şartları buna elverişli olmayabilir. Bu durumda diğer alternatif ulaşım sistemlerini kullanarak çözüm üretmek gerekmektedir. Yerleşkede yaya ve taşıt ulaşımı üç farklı şekilde tasarlanmaktadır. Bunlar:

- Araçlar ile yayaları aynı düzlemde hareket ettirmek. Araçlar ile yayalar aynı düzlemi kullandığından kesişim noktalarında

çakışır böylece sirkülasyon kesintiye uğrar. Bu durumda araçları yerleşke içerisindeki dolaşımını azaltarak yayalara daha fazla dolaşım serbestliği kazandırılır.

- Araçlar ile yayaları farklı düzlemde hareket ettirmek. Araçlar ile yayalar kesişim noktalarında alt ve üst yollar kullandığı için sirkülasyon kesintiye uğramaz ve kullanıcılar tüm birimlere ulaşabilir. Bu tür ulaşım sistemleri maliyet açısından önceki sisteme göre daha az tercih edilir.

- Araçlar ile yayaların aynı ve farklı düzlemde birlikte kullanıldığı karma sistemler.

Yerleşke ulaşım ağı planlaması yapılırken yerleşke girişi, yaya yolları, motorlu araç yolları, bisiklet yolları, bisiklet ve araç otoparkları, yönlendirme ve bilgilendirme levhaları genel olarak değerlendirilmektedir.

3.1. Yerleşke girişi

Yerleşke girişleri genel olarak üniversitelerin kurumsal sembolleri olarak tasarlanmaktadır. Ülkemizde ve dünyada birçok üniversite yerleşke giriş kapıları ile bilinmektedir. Genellikle sanatsal yapılar olarak tasarlanmakta olan yerleşke girişleri aynı zamanda kullanıcıların ihtiyaçlarını karşılayacak nitelikte olmalıdır. Girişler, üniversitelerin büyüme hızları ön görülerek tasarlanmalıdır. Ayrıca yerleşkeye tali girişlerle ulaşılması ön görülmemeyen yoğunluk yaşanması durumunda ulaşım sisteminin aksamadan devam etmesini sağlayacaktır. Yerleşke girişleri, güvenlik taraması ve araç giriş-çıkışlarında yoğunluk yaşanmaması için yaya ve araç olarak farklı mekansal tasarımların yapılması gerekmektedir.

3.2. Araç yolları

Yerleşke tasarımlarında ulaşımın ana belirleyici unsuru olan araç yolları tasarımın iskelet yapısını oluşturur. Yerleşke içerisindeki ulaşım, yaya ulaşımının daha rahat bir şekilde işlenmesini sağlamak ve konumlanan yapılardan taşıt gürültüsünün önlenmesi, araç yollarının öncelikleri arasındadır. Bu kriterler göz önüne alınarak yapılan tasarımda, araç yollarının akademik ve ortak kullanım alanlarının çevresinden planlanarak yaya trafiğinin olumsuz etkilenmemesine dikkat edilmelidir (Türeyen, 2002). Araç yolları planlanırken aynı zamanda otopark alanları da belirlenerek bir bütünlük sağlanmalıdır. Yerleşke içerisinde toplu taşıma araçlarının kolaylıkla hareket

etmesi için yerleşke gelişim planı dikkate alınarak ring hatları oluşturulmalıdır.

3.3. Yaya yolları

Yerleşke tasarımında ulaşım ağının yaya odaklı olarak kurulması ile yerleşkede öğrencilerin ve diğer kullanıcıların hareketleri akıcı ve hızlı şekilde sağlanacaktır. Yerleşke içerisinde tasarlanan yaya sirkülasyonu sayesinde kullanıcılar mekânlar arasında rahat bir şekilde dolaşım sağlayabilmelidir. Şekil 21-22’de yurt içi ve yurt dışından üniversite yaya dolaşım ağına örnekler verilmiştir. Yaya sirkülasyonunun kesintiye uğramaması için kullanılan güzergâhta çeşitli aktivitelere olanak sağlayan mekân tasarımları yapılmalıdır (Öner, 1999).



Şekil 21. Anadolu Üniversitesi – Eskişehir (Url-13)



Şekil 22. Brigham Young University (BYU) (Url-14)

Dober (2000), yaya yolu tasarımında olması gereken konuları şu şekilde belirtmiştir: Yaya ve araç birbirinden ayrı olarak hareket etmelidir. Yaya yolları kesintisiz ve engelsiz bir şekilde kullanıcı yoğunluğu belirlenerek tasarlanmalıdır.


Yaya ve araç yollarının aydınlatılması sağlanmalı ve gece güvenliği için uygun aydınlatma sistemleri kullanılmalıdır. Yaya ve araç yolları ile birlikte bağlantı yolları, fiziksel çevre ile birlikte uyum sağlayacak şekilde tasarlanmalıdır. Yaya yolları planlanırken arazinin topografyasına uygun bir şekilde tasarım düşünülmelidir.

Yerleşke alanlarında yaya sirkülasyonları iki gruba ayrılmaktadır. Birincil yaya yolları ile yerleşke içerisinde bütün alanların dolaşımı sağlanmaktadır. İkincil yaya yolları ise birincil yollara bağlantıyı sağlayan ara yollardır (Türeyen, 2002). Yaya yolları tasarımı yapılırken fiziksel engelli bireyler dikkate alınarak herkes için tasarım sağlanmalı ve engelli bireylerin yerleşke içerisinde hareketliliği kısıtlanmamalıdır. Eğitim, rampa ve park alanları standartlara uygun olarak tasarlanmalıdır.

3.4. Bisiklet yolları


Yerleşke tasarımında ulaşım aracı olarak bisiklet kullanımı, fiziksel aktivite olarak değerlendirilebilir. Ulaşımında bisiklet kullanımı, araç trafiğini azaltacağından, hava kirliliği ve araçlar için tasarlanan geniş otopark alanlarını minimize edecektir. Dünyada, bisiklet kullanımını bir kültür haline getiren Illinois Üniversitesi, Minnesota Üniversitesi, California Üniversitesi gibi üniversiteler vardır (Dober, 2000).

Yerleşke tasarımında tüm yollar birbiri ile uyum içerisinde planlanmalıdır. Bisiklet yollarının, araç ve yaya yolları ile tasarlandığı üç model bulunmaktadır. Bisiklet yollarının araç yolları ile aynı düzlem üzerinde yer aldığı birinci modelde; bisiklet kullanıcıları yolun sağ tarafı kullanılmaktadır. Şekil 23’te birinci model bisiklet yolu görülmektedir.




Şekil 23. Aynı düzlemdeki araç ve bisiklet yolu (Harris, 1988)

Araç yolu bisiklet yolunun aynı hat üzerinde ancak farklı zemin malzemeleri ile birbirinden ayrılarak kullanıldığı ikinci model Şekil 24'te görüldüğü gibidir.



Şekil 24. Aynı düzlemde farklı döşemeli araç ve bisiklet yolu (Harris, 1988)

Son model ise bisiklet yollarının ayrı bir şekilde tasarlanmasıdır. Şekil 25'te üçüncü model olan bisiklet ve araç yolunun ayrı tasarlandığı görülmektedir.



Şekil 25. Ayrı tasarlanmış araç ve bisiklet yolu (Harris, 1988)

3.5. Otopark alanları

Araç yolları ve fiziksel mekânları birleştiren yaya yolları çevresinde büyük bir alana sahip olan otoparkların tasarımı uygun bir şekilde planlanmalıdır (Türeyen, 2002). Yerleşke içerisinde gerekli olmayan alanlarda otopark alanlarının azaltılmasıyla yeşil alan miktarı artırılabilir. Şekil 26-27'de sert yüzeyin çok

kullanıldığı ve yeşil alan öncelikli iki farklı tasarım örneği verilmiştir.



Şekil 26. Capital-One-Campus-Aerial-2011-06 (Url-15)



Şekil 27. Claverton Down kampüsü ziyaretçi otoparkı (Url-16)

3.6. Elektrikli araç şarj alanları

Günümüzde fosil yakıtlı araçların hayatımızdaki yeri giderek azalmaktadır. Fosil yakıtların rezervlerinin azalması ve ayrıca bu tür yakıtların çevreye verdiği zararı azaltmak için yenilenebilir enerji kaynaklarının kullanımına olan ilgi gün geçtikçe artmaktadır. Ulaşım amaçlı kullanılan araçlarda depolanabilir olması avantajı ile elektriği kullanmak günümüzde avantajdır. Araçlarda kullandığımız elektrik bataryalar ile sağlanmaktadır. Bataryalar günümüz teknolojisi ile ancak sınırlı miktarlarda depolanabilmektedir. Sınırlı olan bu enerji ile kısa mesafe yolculuk yapılabilmektedir. Bu yüzden bataryaların sıklıkla şarj edilmesi gerekmektedir. Bataryaların şarj edilmesi kullanıcıların kolaylıkla erişebileceği noktalarda şarj istasyonlarında yapılması ile sağlanır. Şekil 28'de görüldüğü gibi hem gölgelikli otopark hem de şarj istasyonu olarak kullanılacak istasyonlar yapılabilir.



Şekil 28. Hızlı şarj istasyonu (Url-17)

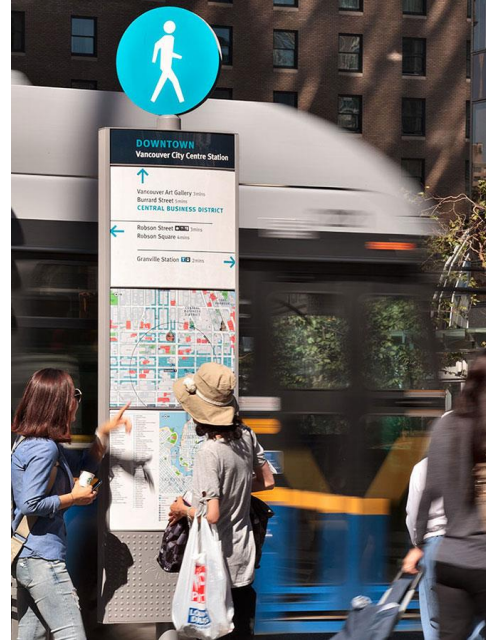
3.7. Yerleşke içi yönlendirme ve bilgilendirme tabelaları

Yerleşkede koordinatlı işaret sisteminin kullanılması, trafik sirkülasyonunun düzgün sağlanmasının yanı sıra ziyaretçilerin ve diğer yerleşke kullanıcılarının alanı kolaylıkla algılamasında önemli rol oynamaktadır (Dober, 2000). Bu nedenle, yerleşkede yerleştirilen bilgilendirme ve yönlendirme tabelalarının uygun boyut ve renklerde, rahatlıkla okunabilir, farklı açılardan yaya ya da taşıt ile gelen kullanıcıların kolayca görebildikleri özelliklerde elemanlar olması gerekmektedir (Dober, 2000). Genelde, kesişim noktalarına yerleştirilmektedir. Yönlendirme tabelası Şekil 29'da gösterilmiştir.



Şekil 29. Yönlendirme tabelaları (Url-18)

Yerleşke alanında, özellikle girişlerde kullanılan ve içinde yerleşke haritalarının bulunduğu bilgilendirme panoları, kullanıcıların yerleşke ile ilgili bilgi almalarını ve alanın genelini algılamalarına yardımcı olmaktadır. Bilgilendirme tabelası Şekil 30'da gösterilmiştir.



Şekil 30. Bilgilendirme tabelaları (Url-19)

4. Yerleşke ulaşım ağı tasarımında AUS sistemleri ve teknolojilerinin kullanılması


Akıllı ulaşım sistemleri; mevcut yol kapasitelerini optimum kullanarak seyahat sürelerini azaltmak, trafik güvenliğini artırmak, mobiliteyi artırmak, enerji verimliliği sağlamak ve çevre kirliliğini önlemek amacıyla geliştirilen, kullanıcı-araç-altyapı-merkez arasında çok yönlü veri alışverişi yaparak, anlık durumu izleme, ölçme, analiz ve kontrolünü sağlayan sistemlerdir. Ayrıca akıllı ulaşım sistemleri, ulaşımında gelişmiş bilgi ve iletişim teknolojilerini kullanarak hareketliliği ve güvenliği artırmayı destekleyen uygulamalar olarak da tanımlanabilir. Akıllı ulaşım sistemleri ile çok modlu ulaşım sistemleri geliştirmek amaçlanmaktadır. Bu yönde ele alınan konular ise; her türlü taşıtın birbirleriyle altyapı ve cihazlarla bağlanması, toplu ulaşım sistemi kurulurken ulaşımın güvenli ve akıcılığı maksimum olacak şekilde hedeflenmektedir. Yollardaki sensörler ve cihazlar kullanılarak araçların hareket hızları ve trafiğin akış durumu sistem merkezi tarafından anlık takip edilebilir.

4.1. Yerleşke mobil uygulamaları

Yerleşke kullanıcılarının kullanımına sunulan mobil uygulama sayesinde yerleşke içerisinde genel aktiviteler ve kent içi toplu taşıma sistemi takip edilebilir. Uygulamayı kullanan yolcular duraklara gelmeden binecekleri otobüsün nerede olduğunu takip ederek olumsuz hava şartlarında duraklarda beklemek zorunda kalmayacaktır.

4.2. Yerleşke içi akıllı duraklar

Olumsuz hava koşullarında toplu taşıma kullanıcılarının en çok sıkıntı çektiği durum duraklarda geçirdiği sürelerdir. Akıllı duraklar ile otobüs bekleyen yolcuların güvenliği 7/24 kameralar ile sağlanmaktadır. Toplu taşıma araçlarının güzergah üzerindeki anlık konumu akıllı duraklarda bulunan bilgilendirme ekranlarından takip edilir. Ön görülemeyen bir durum yaşandığında (trafik kazası) yolcular bilgilendirildiği için zaman kaybına uğramadan farklı ulaşım yöntemini tercih edebilirler. Ayrıca akıllı duraklarda bulunan medya takip ekranları ile yolcular durakta geçirdikleri süre içerisinde eğlenceli vakit geçirebilirler. Akıllı duraklar kendi enerjilerini durakların üzerine konumlandırılan solar paneller ile karşılayabilirler. Bu sayede depolanan enerji ile gece aydınlatması karşılanmış ve yenilenebilir enerji kullanarak ülke ekonomisine katkı sağlanmış olur. Akıllı durak şematik olarak Şekil 31’de gösterilmiştir.



Şekil 31. Akıllı duraklar

4.3. Yerleşke içi akıllı kavşaklar

Trafik yönetiminde kullanılan metotlardan biri olan trafik sinyalizasyon sistemi yaygın olarak kullanılan sistemdir. Taşıtların birbiriyle ve yolcuların taşıtlar ile çakıştığı kavşaklarda karmaşayı önlemek için sinyalizasyon sistemi kullanılmaktadır. Trafik ışıkları ile kavşakta meydana gelen kesişimler süre kullanılarak çözülmeye çalışılmaktadır. Ancak bazı

durumlarda hesaplanan yoğunluğa göre belirlenen süreler yetersiz kalmaktadır. Bu durum kavşaklarda karmaşaya yol açmaktadır. Akıllı teknolojiler ve sensörler kullanılarak kavşaklarda meydana gelebilecek yoğunluklar kurulacak sistem ile mevcut durum değerlendirmesi yapıp yeniden hesaplanır ve trafik ışıkları süreleri güncellenebilir. Böylece karmaşanın önüne geçilmiş oluruz. Akıllı kavşak şematik olarak Şekil 32’de gösterilmiştir.



Şekil 32. Akıllı kavşaklar

4.4. Yerleşke içi akıllı otoparklar

Yerleşke içerisinde otoparkların konumu ulaşım ağının vazgeçilmez faktörlerindedir. İnsanlar genellikle otoparkları kullanırken yapılarla yakın bölgelerde park etmek istemektedir. Bu yüzden otoparklar tasarlanırken araçlarından inen yolcuların tümü en kısa sürede ulaşmak istediği merkeze varabilmelidir. Böylece park alanı homojen olarak kullanılabilir. Akıllı teknoloji sistemlerinin parçası olan sensörler ile boş olan park alanları belirlenerek otopark girişlerinde konumlandırılan panolar ile sürücüler bilgilendirilebilir. Ayrıca akıllı telefon uygulamaları ile otopark sisteminin entegre edilmesi ile kullanıcılar yerleşkeye ulaşmadan park alanlarının durumunu görebilirler. Akıllı otopark şematik olarak Şekil 33’te gösterilmiştir.



Şekil 33. Akıllı otopark


4.5. Yerleşke içi araç şarj istasyonları

Günümüzde fosil yakıtların pahalılığı ve daha temiz çevre anlayışıyla elektrikli araçlara gösterilen ilgi ve yatırımlar artmaktadır. Yerleşke tasarımı yapılırken bu durum göz ardı edilmemelidir. Şarj üniteleri gerek bağımsız alanlarda gerekse mevcut otopark içerisinde tasarlanarak kullanıcıların hizmetine sunulmalıdır. Şarj istasyonlarının ihtiyacı olan enerji mevcut yerleşke elektriğine ek olarak güneş enerjisi kullanılarak karşılanabilir. Oluşturulacak ücret ödeme sistemi ile hem istasyonların enerji ücreti hem de yapılan yatırımın maliyeti kullanıcılar tarafından karşılanmış olunur (Şekil 28).

4.6. Yerleşke içi hız kesici akıllı kasisler

Yerleşke içerisinde tasarlanan trafik yoğunluğunu kontrol altında tutabilmek için dolaşım ağındaki araçların hız limitlerine uymaları gerekmektedir. Malesef insan faktörünün olduğu ulaşım sisteminde bazı sorumsuz sürücüler bu limitleri aşarak diğer araçlar ve yayalar için tehlike oluşturmaktadır. Yol boyunca belli mesafelerde yapılan hız kontrol kasisleri araçlar için bazı durumlarda olumsuz sonuçlar meydana getirecektir. Hız kesici kasisler fark edilemediği zaman araçlar için mekanik zararlar oluşabilecektir. Bundan başka, acil durum araçlarının zaman kaybına uğramasına da neden olmaktadır. Ayrıca, trafik akışının yoğun olduğu günlerde daha fazla

yoğunluğa sebep olmaktadır. Akıllı hız kesiciler, araçların hız durumuna göre hareket ederek ve ışıklı uyarı yardımıyla hız limitine uyan sürücülerin daha sistematik seyrini sağlayacaktır. Sistem acil durum araçlarını tanıyarak zaman konusunda bu araçlara fayda sağlayacaktır. Akıllı hız kesici kasisler şematik olarak Şekil 34'te gösterilmiştir.



Şekil 33. Akıllı hız kesici kasis (Url-20)

4.7. Yerleşke içi ulaşımda otonom araçların kullanılması

Yerleşke içi ulaşım planlamasında tasarlanan ring sisteminde ulaşımın aksamadan devamlığını sağlamak temel faktördür. Gün içerisindeki kullanıcı yoğunluğu değişmektedir. Bu bağlamda yapılacak çözüm insan faktörünü kullanmadan yapılacak otonom araçlar ile ihtiyaca göre sefer ve araç sayısını belirleyerek yerleşke ulaşımda çözüm üretmek olacaktır. Karsan firması tarafından üretilen otonom otobüs Şekil 33'te gösterilmiştir.



Şekil 34. Otonom araçlar (Url-21)

Sonuçlar ve Tartışma

Günümüzde insanlar için en önemli kavram elbette verimliliktir. Gelişen teknoloji ile verimlilik sağlayan akıllı terimi hayatımızın bir parçası haline gelmiştir. Hayatın birçok alanında karşılaşılan akıllı teriminin etkili şekilde kullanılması gerekmektedir. Akıllı telefonlar, akıllı enerji, akıllı evler, akıllı şehirler, akıllı ulaşım gibi birçok kavram hayatımızı kolaylaştırmak için her gün biraz daha gelişmektedir. Geleceğe yönelik planlama senaryosu yapılırken akıllı tasarımların alt

yapısını şimdiden oluşturmak gerekmektedir. Bilimsel ve teknolojik gelişmelerin merkezi olan üniversitelerde akıllı teknolojilerin kullanılması kaçınılmazdır. Üniversite yerleşkeleri tasarlanırken akıllı teknoloji unsurlarının kullanılması, üniversitelerin en önemli paydaşları olan araştırmacılar ve öğrenciler tarafından daha ileri teknolojilerin geliştirilmesine ön ayak olacaktır. Bu çalışmada yerleşkelerin bilimsel ve teknolojik gelişime katkısı bağlamında, bünyesinde ve şehirle arasında uygulanan ve uygulanabilecek akıllı ulaşım teknolojileri anlatılarak ya da önerilerek gelecekte ele alınacak yerleşke ulaşım planlamalarındaki akıllı ulaşım sistemlerinin ve teknolojilerinin uygulanmalarına kaynak oluşturmak amaçlanmıştır. Akıllı ulaşım sistemlerinin ve teknolojilerinin yerleşkelerde etkili kullanımı zaman, enerji, maliyet, kaynak ve alan verimliliği sağlayacağı açıktır. Bunun yanında son yüzyılda insanın hızla tükettiği çevrenin daha az ya da hiç zarar görmediği, çevreye duyarlı yerleşkelerin tasarımında akıllı ulaşım sistemlerinin ve teknolojilerinin kullanılması elzem görünmektedir.

Araştırmacıların Katkı Oranı Beyanı

Yazarların çalışmadaki katkı oranları eşittir.

Destek ve Teşekkür Beyanı

Çalışma herhangi bir destek almamıştır. Teşekkür edilecek bir kurum veya kişi bulunmamaktadır.

Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır

Kaynakça

Akbaş, A., & Akdoğan, E., (2001) *İstanbul Kent İçi Trafik Kontrol Sistemi Üzerine Bir Durum Değerlendirmesi. TMMOB Makine Mühendisleri Odası İstanbul'da Kent İçi Ulaşım Sempozyumu*, 28–30

Auer, A., Feese, S., & Lockwood, S., (2016) *History of Intelligent Transportation Systems. In U.S. Department of Transportation Intelligent Transportation Systems Joint Program Office*

Booth, N. K., (1990) *Basic Element of Landscape Architectural Design*, Waveland Press, Inc., USA

Bozyer, Z., Alkan, A., & Fığlalı, A., (2014) *Kapasite Kısıtlı Araç Rotalama Probleminin Çözümü için Önce Grupla Sonra Rotala Merkezli Sezgisel Algoritma Önerisi. Bilişim Teknolojileri Dergisi*, 7(2)

Dober, R. (2000) *Campus Landscape: Functions, Forms, Features*. John Wiley & Sons, Inc. Printed indökmesci United States of America, ISBN: 0-471-35356-6, 259 p. <http://amazon.com/gp/reader/>

Dopart, K. (2012) About Automation. Retrieved from https://www.its.dot.gov/research_areas/automation.htm Erişim : 09 Ocak 2020

Erkman, U. (1990) *Büyüme ve Gelişme Açısından Üniversite Yerleşkelerinde Planlama ve Tasarım Sorunları, İ.T.Ü. Mimarlık Baskı Atölyesi, İstanbul*

Harris, C., (1988) *Time – Saver Standards for Landscape Architecture Design and Construction Data*, McGraw-Hill, New York.

Hashimshony, R. & Haina, J., (2005) *Designing the University of the Future, Planning for Higher Education*, 34(2), 5-19

Hayashi H. & Morisugi H., (2000) *International comparison of background concept and methodology of transportation project appraisal, Transport Policy*, 7 (1): 73-88 <[https://doi.org/10.1016/S0967-070x\(00\)00015-9](https://doi.org/10.1016/S0967-070x(00)00015-9)>

Karakaş, B. N., (1999) *Üniversite Yerleşkeleri Fiziksel Gelişim Planlama Süreci: Bartın Orman Fakültesi Örneği. Z.K.Ü. Fen Bilimleri Enstitüsü Peyzaj Mimarlığı Anabilim Dalı, Yüksek Lisans Tezi, Bartın*

Koroğlu, D., (1988) *Üniversite yer seçimi için bir model, Doktora Tezi, İTÜ, FBE, İstanbul*

KSU, (2006) *Journal of Science and Engineering* 9(1)

Maruzen Press, Tokyo, (1997) *Japan Society of Traffic Engineers, Intelligent Transport Systems (ITS)*

Öner, S., (1999) *Kütahya Dumlupınar Üniversitesi Merkez Yerleşke Alanı Peyzaj Planlaması, Ankara Üniversitesi Fen Bilimleri Enstitüsü Peyzaj Mimarlığı Anabilim Dalı Yüksek Lisans Tezi, Ankara, 111*

Özaydın, A., (2015). "Bağdat Nizâmiye Medresesi'nin İlk Müderrisi Ebû İshâk Eş-

Şirâzî ve Medresenin Resm-İ Küşâdı". *Şarkiyat Mecmuası*, 26. Erişim tarihi: 2 Ocak 2021

Özen, Ü., (2005) *Üniversite kuruluşunun kent merkezi arazi kullanım biçimine olan etkiler: Çanakkale Örneği, Yüksek Lisans Tezi, İTÜ, FBE, İstanbul*

Peterson, M. P., (2014) *Mapping in the Cloud* Retrieved from https://books.google.com.tr/books?id=xT7q-7fUapsC&pg=PA40&dq=isbn:1462510418&hl=tr&source=gbs_selected_pages&cad=3#v=onepage&q&f=false Erişim:06.01.2021

Rouse, M., (1999) *Flockinglike it's* www.whatis.techtarget.com/definition/heuristic

Sönmezler, K., (2003). *Modern Mimarinin Kentsel Deney Alanı: Üniversite Tasarımı, Doktora Tezi, M.S.Ü. Fen Bilimleri Enstitüsü, İstanbul, ss.9,34*

Türeyen, M.N., (2002) *Yükseköğretim Yapıları - Yerleşke, Tasarım Yayın Grubu, İstanbul*

Tufan, H., (2014) *Akıllı Ulaşım Sistemleri Uygulamaları Ve Türkiye İçin Bir Aus Mimarisi Önerisi, Ulaştırma ve Haberleşme Uzmanlığı Tezi, Ankara*

U.S. Department of Transportation Federal Highway Administration, (2006) *Ramp Management and Control Handbook* Retrieved from https://ops.fhwa.dot.gov/publications/ramp_mgmt_handbook/manual/manual/pdf/rm_handbook.pdf Erişim: 30.12.2020

Ünal, S., (2020) *Üniversite Yerleşkelerinde Peyzaj Tasarımı: Bandırma Onyediy Eylül Üniversitesi Yerleşke Örneği, Ç.O.M.Ü. Fen Bilimleri Enstitüsü Peyzaj Mimarlığı Anabilim Dalı Yüksek Lisans Tezi, Çanakkale*

Yardım, M. S., & Akyıldız, G., (2005) *Akıllı Ulaştırma Sistemleri ve Türkiye'deki Uygulamalar. TMMOB İnşaat Mühendisleri Odası, Ulaştırma Kongresi Bildiriler Kitabı*

Yalçın, E. G., & Büyük, M., (2015) *Otomatik Kaza Bildirim Sistemlerinin Trafik Çarpışmalarının Sonuçları Üzerindeki Yeri ve Önemi. 6. Karayolu Trafik Güvenliği Sempozyumu ve Sergisi, 426*

Url-1 <http://churchesofvenice.com/bolognasanpet.htm>, erişim tarihi 08.05.2021.

Url-2

<https://onedio.com/haber/yurt-disinda-egitim-almak-isteyenler-icin-15-populer-universite-ve-basvuru-kosullari-752721>, erişim tarihi 08.05.2021.

Url-3 <https://www.haberler.com/nizamiye-medresesi-nedir-nizamiye-medresesi-13271671-haberi/>, erişim tarihi 08.05.2021.

Url-4

<http://www.niksar.gov.tr/niksar-yagibasan-medresesi#gallery>, erişim tarihi 08.05.2021.

Url-5

<http://www.fatihkulliyesimedreseleri.com/category/medrese/>, erişim tarihi 08.05.2021.

Url-6

<http://zaferakay.blogspot.com/2014/09/>, erişim tarihi 08.05.2021.

Url-7

<https://nl.pinterest.com/pin/52213676907719697/>, erişim tarihi 08.05.2021.

Url-8

<https://cubiccats.wordpress.com/2009/06/26/26th-june-2009-loughborough-university/>, erişim tarihi 08.05.2021.

Url-9

<http://www.sandiego.edu>, erişim tarihi 08.05.2021.

Url-10

<https://www.fuberlin.de/redaktion/orientierung/media/lageplan-gesamt.pdf>, erişim tarihi 08.05.2021.

Url-11

<https://archive.chicagoacs.net/maps/illinoisstate.html>, erişim tarihi 08.05.2021.

Url-12

<https://www.ruhr-uni-bochum.de/matilda-ma/contact.html.en>, erişim tarihi 08.05.2021.

Url-13

<https://www.enuygun.com/bilgi/turkiye-deki-en-guzel-universite-kampusleri>, erişim tarihi 16.05.2021.

Url-14

<https://www.glassdoor.co.in/Photos/Brigham-Young-University-BYU-Office-Photos-IMG613973.htm>, erişim tarihi 16.05.2021.

Url-15

<https://hwgc.com/projects/confidential-fortune-500-campus-parking-garages>, erişim tarihi 16.05.2021.

Url-16 <<https://www.bath.ac.uk/corporate-information/visitor-car-parking-on-our-claverton-down-campus/>>, erişim tarihi 16.05.2021.

Url-17 <<https://www.solar.ist/ankaranin-en-hizli-sarj-istasyonu-yegm-kampusunde-kuruldu/>>, erişim tarihi 16.05.2021.

Url-18 <<https://www.solar.ist/ankaranin-en-hizli-sarj-istasyonu-yegm-kampusunde-kuruldu/>>, erişim tarihi 16.05.2021.**Url-19** <<http://appliedwayfinding.com/projects/city-of-vancouver/>>, erişim tarihi 16.05.2021.

Url-20 <<https://www.madoors.com.tr/urun/hiza-duyarli-hiz-kesici-kasis>>, erişim tarihi 17.05.2021.

Url-21 <<https://www.star.com.tr/foto-galeri/dunyada-bir-ilk-otonom-atak-electric-yola-cikti-galeri-718131/>>, erişim tarihi 17.05.2021.

Derleme Makale

Hava Taşımacılığında Değişen İş ModelleriVolkan YAVAŞ^{1*}, Ayla ÖZHAN DEDEOĞLU²¹Havacılık MYO, Ege Üniversitesi, İzmir²İİBF, Ege Üniversitesi, İzmir*Correspondence: volkan.yavas@ege.edu.tr

DOI: 10.51513/jitsa.957540

Özet: Havacılık sektöründen bağımsız olarak günümüzde dünya genelinde başta ulaşım, konaklama gibi sektörlerde paylaşım ekonomisi ve medya gibi sektörlerde de üyelik ekonomisi gibi kavramlar popüler hale gelmiş, bu kavramlar Türkiye’de de karşılığını bulabilmiştir. Dünyadaki bu gelişmelere paralel olarak, havacılık sektörü de üyelik ve paylaşım ekonomilerinin birer uygulama alanı haline gelmiş ve bazı öncü uygulamalar havacılık sektöründe de faaliyetlerine başlamışlardır. Bu çalışmanın amacı paylaşım ve üyelik ekonomisi temelli iş modellerinin havacılık sektöründeki kullanım olanaklarını analiz etmektir. Kentsel hava taşımacılığı sistemine ilişkin veriler doğrultusunda havacılık sektöründe değişen, dönüşen ve farklılaşan iş modelleri üzerinden hava taşımacılığında gelecekte yaygınlaşması öngörülen kavramlar tartışılmıştır.

Anahtar Kelimeler: Hava Taşımacılığı, Paylaşım Ekonomisi, Üyelik Ekonomisi, İş Modelleri, Havayolu Pazarlaması

Changing Business Models in Air Transportation

Abstract: Regardless of the aviation sector, today the concepts of sharing economy in sectors like transportation, accommodation, and subscription economy in sectors like media have become popular around the world and have found their value in Turkey. Correspondingly, the aviation sector has also become an application area of subscription and sharing economies, and some pioneering applications have also started their activities in the sector. The aim of this study is to analyze the use opportunities of sharing and subscription economy-based business models in the aviation sector. According to the data on the urban air mobility, trends that are expected to spread in the future in air transport through changing, transforming and differentiating business models in the aviation sector were discussed.

Key words: Transportation, Sharing Economy, Subscription Economy, Business Models, Airline Marketing

* Corresponding author.

E-mail address: volkan.yavas@ege.edu.tr

Received 25.06.2021; accepted 19.08.2021

Peer review under responsibility of Bandirma Onyedi Eylül University.

Giriş

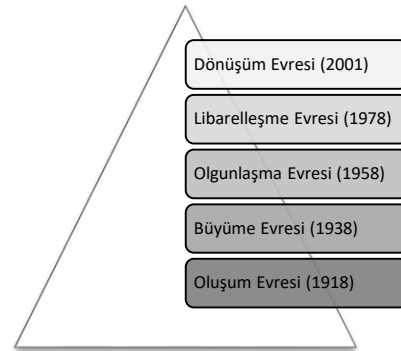
Havacılık endüstrisi, kıtalar arasında insanları, kültürleri ve ticareti birbirine bağlayan en küresel endüstrilerden biridir. Dünya genelinde yalnızca ulaştırma ağı yaratmakla kalmayıp, küresel iş hacminin de önemli aktörlerinden biri olarak ekonomik büyüme ve istihdama katkı sağlayan, uluslararası ticaret ve turizmi kolaylaştıran ve küresel ekonomik yapıda önemli katkıları olan bir endüstridir (IHLG, 2019). Küresel anlamda önemli yapı taşlarından biri olan hava taşımacılığı, ticari olup olmamasına bakılmaksızın insan, kargo ve postanın hava aracı ile yer değiştirmesi faaliyeti olarak tanımlanmaktadır (Gerede, 2015).

Havacılık tarihinin miladi olarak kabul edilen 1903 yılı itibariyle ticari hava taşımacılığı sisteminin günümüz hava taşımacılığına gelene kadar geçen süreci Wensveen (2007) tarafından dört evrede incelenmektedir; 1918-1938 tarihleri arasında ilk posta taşıması ve Pan America ile başlayan Oluşum Evresi; 1938 – 1958 tarihleri arasında II. Dünya Savaşının etkisiyle yaşanan Büyüme Evresi; 1958 – 1978 tarihleri arasında jet motorlu uçakların damga vurduğu Olgunlaşma Evresi ve 1978 tarihinden günümüze kadar gelen Liberalleşme Evresi. Tüm bu gelişim evresinde de havayolu işletmeleri artan rekabet içerisinde var olabilmek ve büyüebilmek adına çeşitli iş modelleri ve stratejilerle faaliyetlerini sürdürdükleri bilinmektedir.

Sivil havacılık tarihine yönelik bu çok bilinen dört evrenin günümüz ekonomik, sosyal ve teknolojik anlamda değişen tüketici ihtiyaçlarına cevap verme konusunda yetersiz kaldığı görülmektedir. Modern hava taşımacılığının doğduğu, büyüdüğü ve gelişimini sürdürdüğü 20. Yüzyılda havacılık sektörüne dair önemli adımlar atılmış iken 21. Yüzyıl itibariyle de tüketici odağında farklılaşan bir talebin söz konusu olduğu da göz ardı edilmemelidir. 21. Yüzyılda ekonomik güce ve statüye sahip olan Y Kuşağı'nın sektördeki artan talebi ile Z kuşağının da kısa ve orta vadede söz sahibi olacak olması tüketici davranışlarında ve talebinde değişiklik yaratması olası bir sosyal durumu ifade etmektedir. Y Kuşağı tüketicilerin ulaşım sektörüne yönelik teknolojik ve inovatif bir beklenti içerisinde olduğu ve hatta otonom araç teknolojilerine katılım eğilimine de sahip oldukları ifade edilmektedir (Dewalska-Opitek,

2017). Z kuşağı tüketiciler de Y kuşağına benzer özelliklerin yanı sıra sosyal, ekonomik ve çevresel konulara duyarlı, teknoloji ve dijitalleşme odaklı ve daha az mülkiyet daha çok ilişkiye dayalı karakterlere sahip olmaları ve benzer davranışlar sergilemeleri sebebiyle paylaşım ekonomisini yeni yönlendiricileri olarak değerlendirilebilir (Martínez-González vd, 2021).

Diğer yandan 2011 yılı itibariyle Endüstri 4.0 kavramının ortaya çıkması ve birçok sektörde dijitalleşme ve teknolojik inovasyon çalışmalarının yaygınlaşması da sektörde ekonomik ve teknolojik anlamdaki değişikliklerin habercisidir (Sabella vd, 2020). Bu sebeple klasik hava taşımacılığı evrelerinin Şekil 1'de gösterildiği gibi 21. Yüzyıl itibariyle yeni bir evre ile (Dönüşüm evresi) ile değerlendirilmesi gerektiği düşünülmektedir.



Şekil 1: Hava Taşımacılığın Evreleri


Kaynak: Yazarlar tarafından oluşturulmuştur.

Bu çalışmanın amacı da hava taşımacılığında geleneksel anlamda uygulanan ve doyunluğa ulaştığı düşünülen iş modellerinin 21. Yüzyıl itibariyle dönüşümüne dair mevcut uygulamaları derleyerek değerlendirmektir. Bu derleme dünyadaki ekonomik dönüşümde payı olan üyelik ve paylaşım ekonomisi odağında ekonomik ve sosyal; Endüstri 4.0 odağında ise teknolojik gelişmeleri içermektedir.

1. Havayolu İşletmelerinin İş Modelleri ve Stratejileri

Havayolu işletmelerinin, hava taşımacılığı sektörünün en kritik rollerinden birini üstlenerek tüm bileşenleri birbirine bağlayan, bir başka ifade ile tüm bileşenlerin etrafında


organize olduğu bir pazar mekanizması görevi gördüğü söylenebilir. Hava taşımacılığı sisteminde arzın vitrininde yer alan bu aktörleri, Uluslararası Sivil Havacılık Örgütü (ICAO), “hava araçlarını kullanarak belli bir ücret karşılığı ulaştırma hizmetini sağlayan girişimler” olarak tanımlanmakta ve Şekil 2’de gösterildiği üzere altı farklı şekilde kategorize etmektedir (ICAO, 2004).



Şekil 2: Havayolu İşletmelerinin Sınıflandırılması

Kaynak: ICAO, 2004

Geçmişten günümüze değişen sektörün dinamik, rekabetçi yapısı ve ekonomik, politik vb. dış etkenlere karşı kırılgan oluşu gibi birçok faktörün etkisiyle pazarda yer alabilmek ve karlılıklarını korumak ya da arttırmak adına havayolu firmaları çeşitli iş modelleri geliştirmek ve uygulamak durumunda kalmaktadırlar (Budd ve Ison, 2017).



Şekil 3: Havayolu İş Modelleri

Kaynak: Budd ve Ison, 2017

Hali hazırda kullanılan temel iş modelleri Şekil 3’te görülmektedir. Network – Ağ taşıyıcılar (bayrak taşıyıcılar), sektörde ilk olarak kurulan Türk Hava Yolları ve Amerikan Airlines gibi

büyük bir ağda hizmet veren havayollarını ifade etmektedir. Düşük maliyetli taşıyıcılar (Low Cost Carriers: LCC’s) ise pazarda farklı iş modeliyle rekabet etmeye çalışan Pegasus ve Ryanair gibi daha ekonomik fiyatlar ve hizmetler sağlamayı amaçlayan firmalar için kullanılmaktadır. Bu iki modelde de tarifeli bir planlama ile hizmet verilmekte iken bunların dışında kalan charter taşıyıcılar ise tarifersiz planlama odaklı bir hizmet sunmaktadır. Bölgesel taşıyıcılar daha çok ABD’de sıklıkla kullanılan bir model olup, büyük coğrafyalar için tercih edilirken; özel servisler ise hava taksi vb. iş modelleri olarak da düşünülebilir. Temel modeller arasındaki kesişim kümeleri de büyük firmaların alt firması / ona bağlı olarak çalışan havayolu taşıyıcılarını tanımlamak için kullanılırken, 3 temel modelin kesişiminde yer alan Hibrit modeller ise bir melez (karma) iş modeli seçeneklerini ifade etmek için kullanılmaktadır.

Günümüzde havayolu taşıyıcılarını eskisi kadar kolay şekilde düşük maliyetli taşıyıcı ya da tam hizmet sağlayıcı (network) havayolu olarak etiketlemek kolay değilken, yeni havayolları da hibrit adı verilen sistemlerle rekabete dahil olmaya çalışmaktadırlar. Havayolu işletmeleri açısından hibrit iş modelleri, rekabet ortamında ayakta kalmak ve hedef talebi genişletmek adına network (ağ) taşıyıcı ve düşük maliyetli taşıyıcı özelliklerini bir araya getirerek oluşturdukları modeller olarak tanımlanmaktadır (Lohmann ve Koo, 2013). Bu doğrultuda birçok düşük maliyetli taşıyıcının da iş modellerini hibrit modele çevirmeye başladığı belirtilmektedir (Klophaus, Conrady ve Fichert, 2012). Bunun temel sebebi olarak da birçok pazarın doyum noktasına ulaşması ve düşük maliyetli taşıyıcıların büyük bir rekabet baskısı altında kaldıkları için hizmetlerini genişletmek durumunda kalmaları olarak gösterilmektedir (Corbo, 2017). Bunun yanı sıra, pazarın rekabet durumu ve dinamik yapısıyla beraber, artan sayıda havayolu firmasının da pazara girmesi, özellikle daha küçük yapıda olan firmalar, niş pazarlara yönelik arayışlarını – Alman Air Berlin ve İrlandalı Aer Langus gibi – hibrit modellere dönüşüm olarak yansıtmışlardır (DLR, 2008).

Stratejik açıdan bakıldığında ise havacılık sektöründe yer alan aktörlerin rekabet avantajı elde edebilmesi adına birçok farklı strateji söz konusu iken bunların belki en bilineni ve kullanılanı ise Micheal Porter’ın “Maliyet

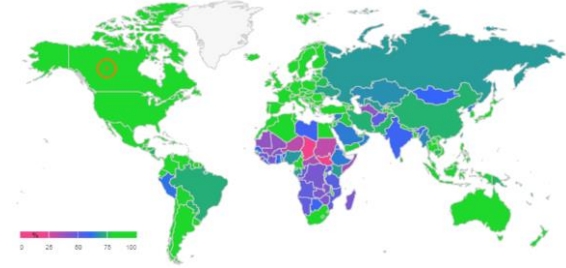
Liderliği, Farklılaşma ve Odaklanma” olarak kategorize ettiği Jenerik (Rekabetçi) Stratejisidir (Porter, 1996). Jenerik Strateji 'ye göre havayolu firmaları ücrete duyarlı yolcular için Ryanair örneğinde olduğu gibi “düşük maliyet / maliyet liderliği” merkezli bir strateji, özellikle ABD’de coğrafik açıdan Aloha Airlines ve üretici açısından Concorde örneklerinde olduğu gibi rakiplere kıyasla ihtiyaçlara cevap verebilen farklılaştırılmış hizmet sunmasıyla “odaklanma” ve sektörde diğer rakiplere kıyasla ve müşterilerinde ekstra ödemeye istekli olmasıyla ürün/hizmetlerini “farklılaştırma” seçeneğini öne çıkaran Singapore Airlines örneği olacak şekilde rekabet stratejileri belirlemektedirler (Flouris ve Oswald, 2006).

Hava taşımacılığı sektörünün geçmişten günümüze kat ettiği mesafe ve radikal değişiklikler dikkate alındığında gelecekte de benzer bir değişim göstermesi beklenebilir. 2025 yılında sivil havacılık sektörünün durumunu tahmin etmeye yönelik yapılan bir çalışmaya göre gelecek vizyonu açısından çeşitli bakış açılarıyla ortaya 40 adet olasılık ortaya konmuştur (Linz, 2012). Söz konusu çalışmada geçen bazı değişimler şöyledir:

- İş amaçlı ve genel amaçlı taşımacılıkta zaman kaybını azaltacak “kolay” uygulamalara talebin artması,
- Yolcuların daha fazla özelleştirilmiş hizmet talep ederken iş ve kargo amaçlı taşımacılık talepleri de daha fazla entegre (kapıdan kapıya) hizmetler talep etmesi,
- Global ekonomik krizler, yakıt fiyatlarında artış, savaş, salgın hastalıklar, terörizm, volkanik patlamalar vb. gibi beklenmedik olaylar nedeniyle sektörün kırılabilirliğinin artması,
- İş amaçlı ve lüks tüketim amaçlı uçuşların artması ile jet pazarında daha küçük uçaklar daha uzun mesafeler ve noktadan noktaya seyahat için uygun hale gelmesi.
- Havacılık sektöründe belirsizliğin sürmesi sonucunda, iş amaçlı ve benzer amaçlı uçuşların bir havuz içerisinde yönetilmesi.

Havacılık sektörünün geleceğine yönelik yapılan bir diğer araştırmada (Alexander ve Natarajan, 2017) 2025 yılında teknolojik gelişmelerin, değişen müşteri tercihlerinin, küresel dalgalanmaların ve rekabet savaşının

radikal bazı aksiyonlar alınmasına sebep olabileceği ve bu doğrultuda havacılık sektörünün geleceğinde “tahmin edilmeyen/beklenmeyen” ekonomik, teknolojik, yenilikçi ve demografik/sosyolojik odaklı yeni yaklaşımlar ile birlikte yeni iş modellerinin ortaya çıkacağı öne sürülmektedir. Paylaşım ve üyelik ekonomisinin de hava taşımacılığında başarılı şekilde uygulanması beklenmektedir.



Şekil 4: Havalimanı Erişimi

Kaynak: URL7

Bugün dünya nüfusunun %51’i uluslararası bir havalimanına, %74’ü herhangi bir havalimanına 100 km altında mesafede yaşarken, Şekil 4’te ülkelerin vatandaşların yüzde olarak havalimanlarına erişimini gösteren grafik de bunu doğrular niteliktedir (ICAO, 2021). Uluslararası Sivil Havacılık Örgütü ICAO, 2036 yılında dünya genelinde hava taşımacılığında erişimin ve dolayısıyla da hava trafiğinin ciddi oranda artacağını tahminlerken bunu olanaklı kılacak inovasyonlara şimdiden ihtiyaç duyulduğunu ifade etmektedir. Daha hafif, sessiz ve verimli hava araçları ve komponentleri tasarlanmaya başlanmıştır. Endüstri 4.0 bileşenlerine uygun yaklaşımların genişleyeceği ve insansız hava araçlarıyla sadece kargo değil yolcu da taşınacağı öngörülürken tüm paydaşların değişim sürecine hızlıca adaptasyon ve katılım sağlamanın önemli olduğu belirtilmektedir (ICAO, 2020). 2050’li yıllara gelindiğinde insanlığın üçte ikisinin şehirlerde yaşayacağını, temel ihtiyaç haline gelecek olan hava ulaşımında hız, etkinlik, bağlantı ve erişimin temel müşteri beklentileri olarak yerini koruyacağını belirtmektedir (ICAO, 2020).

Rekabetin çok katı yaşandığı havacılık sektöründe işletmelerin var olabilmeleri ve sürdürülebilirliğini sağlayabilmek adına geleneksel havayolu iş modellerine kıyasla inovatif bir yaklaşımla pazarda yer alması fark

yaratabilir. Bu noktada önemli olan strateji pazar dinamiklerini ve müşteri beklentilerini iyi analiz ederek bir iş modeli belirlemek ve bu modeli esnek bir şekilde sektördeki beklentileri uygun olarak şekillendirebilmektir (Pereira ve Caetano, 2015).

2. Paylaşım ve Üyelik Ekonomisi

Paylaşım ekonomisi ve üyelik ekonomisi kavramları son yıllarda dünya genelinde birçok ülkede insanların ilgisini çekmeye başlamıştır. Paylaşım ekonomisi bireylerin birbiriyle iletişimini kolaylaştıran, bilgi ve iletişim teknolojilerinin gelişimiyle beslenen, kitlesel üretim ve tüketim anlayışından çok paylaşımı ön plana koyan yeni bir ekonomik modeldir (Roh, 2016). Richter, Kraus ve Syrjä'ya (2015) göre ise modern bilişim teknolojisinin olanaklı kıldığı paylaşım ekonomisi, “dijital içerikler, fiziki ürünler ya da yeterince kullanılmayan ürün/hizmetlere ulaşım sağlayan ticari, kültürel ya da sosyal projelerde katılımın paylaşılmasına dayalı ekonomik bir model”dir.

Literatürde yer alan çeşitli çalışmalarda paylaşım ekonomisi kavramının gelişiminde, özellikle sosyal ağlar ve mobil teknolojinin yaygınlaşmasının bu modelin yükselmesinde etkili olduğu belirtilmektedir. Daha az tüketimi ve harcamayı mümkün kılan bu model Time Dergisi tarafından gelecekte dünyayı değiştirebilecek on büyük fikirden biri olarak gösterilmektedir (Demirer ve Hassan, 2016).

Türkçe 'de birbirlerinin yerine kullanılan üyelik (membership) ve abonelik (subscription) kavramları üzerine inşa edilen üyelik ekonomisi ise uluslararası literatürde de iş modeli olarak kavram karmaşası yaratan bir ikileme haline gelmiştir. Üyelik bir davranış, bir duyguyu ifade ederken; abonelik finansal bir anlaşmayı ifade ettiği ve her ikisinin bir organizasyon/bir etkinlik içerisinde beraber olmasının da oldukça mümkün olduğu; üyelik ekonomisinin abonelik kavramının mantıksak bir uzantısı olduğu belirtilmektedir (Baxter, 2015). “The Membership Economy” isimli kitapta ilgili kavram “abonelikten, aidiyete, iletişimden, sosyalleşmeye kadar birçok kavramı içinde barındıran ve en genel anlamıyla bir kurum ya da grupta resmi olarak devam arz edecek bir şekilde ticari bağ kurmak” olarak tanımlanmaktadır (Baxter, 2015).

Müşterilerin periyodik ve yinelenen şekilde bir ürün ya da hizmete erişimini sağlayan işletmeleri/girişimleri kapsayan Üyelik Ekonomisi kavramı son yıllarda dikkat çekici bir popüleriteye ve büyümeye sahipken; önceki yıllarda gazete, magazin ve iletişim firmalarının egemenliğinde olan ancak sonradan yazılım, gıda, güzellik – sağlık vb. birçok geniş yelpazede yeni ürün hizmetlerle kendine yer bulan bir model haline geldiği de görülmektedir (McCarthy, Fader ve Hardie, 2017).

Üyelik ekonomisi fiyatlandırma açısından da basit ve sürdürülebilir olmasının yanı sıra firmanın gelirlerinin sürekliliğini ya da devamını sağlaması açısından üreticiler ve tedarikçiler için fayda sağlamaktadır. Ayrıca kullanım süresinden daha uzun süreli anlaşmalardan ve yüksek ücretlerden kaçınma, daha iyi teknik destek ve yüksek kaliteli hizmet alabilme açısından da tüketicilere de fayda sağlayan bir modeldir (Wang, 2009).

Paylaşım ve üyelik ekonomisi kavramları dünya literatüründe farklı isimlerle, farklı sektörlerde varlığını ve popülerliğini sürdürürken bazı durumlarda çeşitli kavram karışıklıklarına da sebebiyet verdiği bilinmektedir. Baxter (2015) yayımlanmış olduğu kitabında paylaşım ekonomisi kavramının üyelik ekonomisi kavramıyla oldukça yakın bağlantılı olduğunu, birçok başarılı paylaşım ekonomisi platformunun üyelik ekonomisi temelli olduğunu; üyelik ekonomisinin bir güven altyapısı oluşturduğunu ve paylaşım ekonomisinde de insanların bu altyapı üzerinden ağlarını genişlettiğini belirterek; paylaşım ekonomisini üyelik ekonomisinin bir alt kümesi olarak gördüğünü vurgulamaktadır. Buna karşılık her iki kavramı da ayrı olarak inceleyen literatür de mevcuttur (Xiang, Ogata ve Futatsugi, 2007).

3. Hava Taşımacılığında Paylaşım ve Üyelik Ekonomisi Temelli İş Modelleri

Wright Kardeşlerin 1903 yılındaki ilk motorlu uçuşundan bu yana var olan sivil havacılık sektörü yaklaşık 120 yıllık bir süreçte büyük ve radikal değişiklikler ve gelişme gösteren ender sektörlerden biridir. Temelde ABD'nin öncülük ettiği serbestleşme hareketi, sık uçan yolcu programları, hava taksi hizmetleri gibi birçok farklı ve önemli değişiklikler yaşandığı ve bunun da sektörün dinamik yapısı ve her geçen gün talebinin artmasıyla doğrudan ilişkili olduğu görülmektedir.

Bu değişikliklerin ve yeniliklerin en güncel örnekleri olarak da paylaşım ve üyelik ekonomisinin havacılık sektöründeki girişimleri gösterilebilir. Bu girişimlerden ilki olan 1964 yılında ABD’de kurulan dünyanın ilk özel jet kiralama ve yönetim şirketi olan Netjets, özel jet sektöründe dünyanın lider firması olarak aralarında Türkiye’nin de bulunduğu dünya genelinde 180’nin üzerinde ülke ve 3.000’ün üzerinde havalimanında hizmet vermektedir. Havacılık sektöründe üyelik ekonomisinin en iyi örneklerinden birini sergileyen işletme, müşterilerine Netjets Share, Lease ve Marquis Card isimli 3 farklı seçenek ile müşterilerin uçuş saati ve hizmet taleplerine yönelik olarak bir hava aracı sahibi olmaksızın firmanın filosuna erişim imkanı sağlayan bir hizmet sunmaktadır (Netjets, 2020). Bunun yanı sıra “fractional ownership” olarak da bilinen ortak sahiplik ya da hisseli iş jeti satışı kavramını da dünyaya tanıtan (Ozkan, 2020), bu yönüyle de paylaşım ekonomisinin bir yansımasını ortaya koyduğu görülmektedir.



Şekil 5: Netjets Firması Reklamı

Kaynak: URL1

Benzer bir diğer örnek olan 2004 yılında kurulan Vistajets Dünya genelinde 70’in üzerinde uçak ve 1.900’ün üzerinde havalimanında yolcularına hizmet veren, katılımcıların uçak sahibi olmadan yalnızca ihtiyaç duydukları saatlere yönelik bedel ödeyerek hava aracı hizmetinden faydalanabildikleri üyelik ekonomisi modelini uygulayan bir platformdur. Aynı zamanda tek yön uçuşların dönüşünde, bir başka ifadeyle boş uçuşları da müşterilerine sunarak paylaşım ekonomisi modelini de uygulamaktadır (Vistajets, 2020).



Şekil 6: Vistajets Boş Uçuş Teklif Platformu

Kaynak: URL2

Dünyanın öncü hava charter uçuş platformu olarak kendini lanse eden Avinode platformu, alıcı ve satıcıların buluştuğu dünyanın en geniş, en aktif ve en bilinen hava charter platformu olarak faaliyetlerini sürdürmektedir. Sistem yolcu bazında üyeliğe izin verse de genel amacı hava aracı sahipleri/sağlayıcıları ile brokerları buluşturarak, müşterilere hizmet sağlama yolunu açan pahalı bir platformdur. Örneğin broker olarak sisteme girmek için 3 farklı seviyede ve aylık 599 Euro ve 1.799 Euro arasında değişen bedellerle üyelik teklifi sunulurken, hava aracını bu sisteme dahil edip paylaşımına sokmak isteyen operatörler için ise aylık 270 Euro bir üyelik bedeli istenmektedir.




Şekil 7: Avinode Sistemi Kullanım İstatistikleri

Kaynak: URL3

Dünya’daki öncü örnekler Netjets ve Vistajets’e benzer bir iş modeli ile 2016 yılında Türkiye merkezli olarak kurulan Jetforme platformu, kullanıcılar ve tedarikçileri buluşturarak uygun fiyatlarla özel uçuş deneyimi sağlamayı vadeden bir iş modeli üzerine faaliyetlerini sürdürmektedir. Bu girişim, “Blablacar” girişimine benzer şekilde yolcular ve jet sahiplerini buluşturan interaktif bir platform olarak hizmet vermektedir. Web sitelerindeki bilgiye göre yaklaşık 1.000 jet sahibinin katılımıyla 40’ın üzerinde ülkeye hizmet verebilmekte olduğu belirtilmektedir (Jetforme, 2019). Netjets ve Vistajets örneğinde olduğu gibi anlık ya da blok saat olarak kiralama ile üyelik ekonomisi sistemi

örneklerinin yanı sıra, Vistajets örneğinde olduğu gibi boş uçuşları da sisteminde sunarak paylaşım ekonomisi örneği de sergilediği bir iş modeline sahiptir.

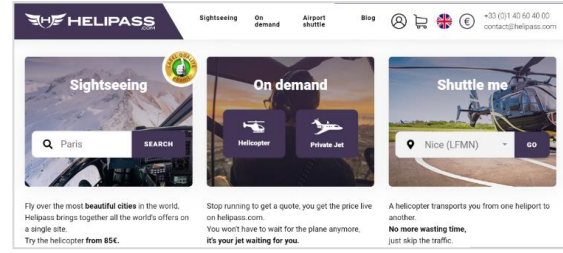
Cognizant'ın 2017 yılında yayınladığı “The Road To 2025” isimli raporuna göre kara taşımacılığında hızla gelişen (UBER vs.) paylaşım ekonomisi odaklı modellerin havacılık sektöründe de “Jettly ve JetSuite” gibi öncü firmalarla başladığı; “Surf Air ve Airly” gibi girişimlerle de üyelik ekonomisinin örneklerinin ortaya çıktığı belirtilmiştir (Alexander ve Natarajan, 2017). Yine aynı raporda yer verilen bilgi ve istatistikler ışığında, 2025 yılı itibariyle havacılık sektöründe üyelik ekonomisinin, paylaşım ekonomisinden çok daha etkin bir şekilde kullanılacağı tahmin edilmektedir.



Şekil 8: Wingshare Platformu

Kaynak: URL4

Paylaşım ekonomisi açısından ise Fransa'daki Wingshare isimli girişim ile araç/sürüş paylaşımına benzer bir modelin uçak paylaşımına uyarlandığı ve özel uçaklar, özel pilotlar ve müşterileri birleştiren bir organizasyon oluşturulması da bu yeni modellere bir başka örnek olarak gösterilebilir. Fransa merkezli bir başka benzer platform olan Helipass ise helikopter ağırlıklı olmakla beraber özel hava araçlarıyla hizmet veren, müşterilerine profesyonel bir hava taksi hizmeti vermenin yanı sıra, transfer ve tur gibi teklifler de sunan bir başka model olarak öne çıkmaktadır. Bunun yanı sıra Wingshare platformuna nazaran daha profesyonel olarak gözüken Wingly platformu da benzer bir iş modeli ile ilgililere müsait rotalarda uçak seyahati ve planlanan ve talebe göre şekillenen şehir bölge turları teklifleri sunmaktadır.



Şekil 9: Helipass Platformu

Kaynak: URL5

Simple Flying isimli web sitesinde havayolu taşımacılığında üyelik ekonomisine yönelik yayımlanan bir makaleye göre hemen hemen tüm tüketicilerin TV, medya, spor, müzik vb. gibi alanlarda bir üyeliği bulunurken ve bu kişilere her seferinde satın alma işlemleriyle uğraşmama ve istediğin zaman kullanabilme gibi kolaylıklar sağlarken havayolu taşımacılığında yolcular için kolaylık, firmalar için de rekabetten sıyrılabilme avantajı sağlayan böyle bir yapının neden olmadığı sorgulanmakta ve aslında hâlihazırda La Compagnie, SurfAir, JetBlue, Wanderrift gibi firmaların bu sistemi kullandıkları belirtilmektedir (Cummins, 2019).

Fransız La Compagnie firması “We Love Business” kampanyası ile Atlantik seyahati yapan müşterileri için 1 yıl süreli olmak üzere “Pass” biletler hazırlayarak, bunları 20 Pass, 35.000\$, 50 Pass 80.000\$ ve 100 Pass 150.000\$ olacak şekilde fiyat sabitlemesi yaparak, ilgili müşterilerine esnek ve daha uygun maliyetli uçuş imkânı tanırken bu imkânın da öznel olmayarak herhangi biri için kullanılabileceğini belirtmektedir (La Compagnie, 2019). Amerikan Surf Air firması ise tamamen üyelik ekonomisi modeli ile çalışırken yolcuların profiline göre az seyahat eden bireysel yolcular için yıllık 2.500\$ ücret talep ettiği ve uçuş başına indirim sağladığı “Surf Air Express”; sık uçan bireysel yolcular için aylık 1.950\$ ücretli “All-You-Can-Fly” ve şirketler/aileler için uygun kişiye özel olmayan aylık 5.000\$ ücretli “Group” seçenekleriyle yolcularına “üyelik ekonomisi” modelinde hizmet vermektedir (Surf Air, 2019).

Amerikan düşük maliyetli havayolu taşıyıcısı Jet Blue, “All You Can Jet” isimli kampanyasıyla yolculara üyelik ekonomisi fırsatı sunmuş, aylık 599\$ ücret karşılığında yolcularına istedikleri noktalara uçuş imkânı

sağlamış ancak kampanyadan istedikleri sonucu alamadıkları için kısa bir süre sonra kampanyayı sonlandırmıştır. (Cummins, 2019). Onego isimli bir web sitesi de A.B.D. içerisinde ülke genelinde 76 havalimanını içeren 2.950\$ aylık ücretli, batı kesiminde 14 havalimanını içeren 1.500\$ aylık ücretli, orta merkezde yer alan 18 havalimanıyla 1.950\$ aylık ücretli ve doğu kesiminde 39 havalimanını içeren 2.300\$ aylık ücretli 4 farklı paketle ve sisteme ilk kayıt ücreti olan 495\$ ücretle ABD vatandaşlarına üyelik ekonomisi hizmeti sağlarken 2017 yılı itibarıyla web sitesinin kapandığı görülmektedir (McNutt, 2016).

Hava taşımacılığının dev firmalarından Amerikan United Airlines, üyelik ekonomisi kavramını biraz daha genişleterek müşterilerine uçuşlarda üyelik sistemi seçeneğinin yanı sıra, Lounge gibi özel alanlarda, bagaj hakkında hatta uçak içi internet hizmetlerinde çeşitli seçenekler sunarken, Frontier Airlines “Discount Den” ve Spirit Airlines “\$9 Fare Club” adını verdikleri üyelik sistemi ile yolcularına yıllık 59,99\$ dolar karşılığında en uygun biletler/indirimler ve çeşitli diğer olanakları sağlamayı taahhüt etmektedirler. Bir başka farklı örnekte ise SkyHi isimli girişimde, aylık \$199 dolar karşılığında Kuzey Amerika ve Avrupa’daki yaklaşık 80 havalimanına 5 sefer olmak üzere uçuş fiyatlarını sabitleyerek, 0 – 1000 mil (Yaklaşık 1600 km) arası \$35, 1000 – 2000 mil arası \$75 ve 2.000 – 3.000 mil arası \$120 sabit ücretle uçuş hakkı satın alınan bir hizmet sunulmaktadır. Üyelik ekonomisinin Türkiye’de ilk örneklerinden biri olan fakat 2020 yılı içerisinde iflasını açıklayan AtlasGlobal Havayolları’nın Unlimited kampanyası ile ise şirket, yolcularına 2.999 Euro ücret karşılığında 5 ay boyunca tarifeli uçuş yapılan yurtdışı rotalarına Business Class konforuyla sınırsız seyahat hakkı tanımaktaydı (AtlasGlobal, 2019).

4. Hava Taşımacılığında İş Modellerinin Geleceği ve Dijitalleşme

Hava taşımacılığı dahil tüm ulaşım modları en özet haliyle tarifeli ve tarifersiz olarak bölümlendirilebilmekte; tarifeliden farklı olarak tarifersiz taşımacılık biraz daha değişken unsurlara sahip olan ancak talebe yönelik taşımacılık (on-demand) olarak adlandırıldığında daha tanımlayıcı olan ve ihtiyaç halinde müsaitliğin bulunmasını ifade eden bir sistemdir (Sheehan, 2003). Talebe

yönelik taşımacılık sistemi de bireylerden, şirket yöneticilerine, teknik sebepli ihtiyaçtan, spor takımları, girişimciler ve aileler gibi birçok kesimin faydalanabildiği, temel amacı ihtiyaç doğrultusunda belli noktalar arasında emniyetli, konforlu, bazıları için prestij bazıları için ekonomiklik sebepleriyle tercih edilen ve en öz haliyle tüm kullanıcıların kendi hayatlarını ya da zamanlarını kontrol edip planlamasına izin verebilen bir sistem olarak tanımlanabilir (Sheehan, 2003).

Benzer şekilde Küçük Hava Taşımacılığı (Small Air Transport) kavramı da yakın tarihte ABD’de olduğu kadar Avrupa’da da giderek artan talebiyle, en fazla 19 kişilik uçaklar ve bölgesel amaçla hizmet sağlamayı vadederken, geleneksel havayolu taşımacılığına kıyasla da yakıt tüketimi, daha kısa geri dönüş süreleri ve artan ekonomik uygulanabilirliği ile de dikkat çekmektedir (Di Vito vd, 2021). Bu gibi iş modelleri de yine paylaşım ekonomisi veya üyelik ekonomisi modellerine uygun, başka bir ifade ile onların yansıması olarak da ifade edilebilir.

Paylaşım ve üyelik ekonomisi odaklı iş modellerinin yanı sıra havayolu taşımacılığının geleceğine yönelik en dikkat çekici gelişmelerden biri de TESLA, UBER vb. işletmelerin öncülüğünü yaptığı ve ütopyik olarak görülen, 1962 – 1987 yılları arasında yapılan Jetgiller çizgi filmine benzer araçlarla hava taksi hizmetlerinin, bir başka ifade ile talebe yönelik taşımacılık sisteminin 2020’lerden sonra başlayacağını öngörülmesidir (Airporthaber, 2019).

Bir ayağı paylaşım ekonomisine de dayanan ve karayolunda yoğun yatırım ve çalışmalarla örnekleri ortaya konan, tüketicilere güvenli ve konforlu ulaşım seçeneği sunan otonom araç teknolojisinin bir sonraki basamağı gökyüzü olarak gözükmemektedir (Al Haddad vd, 2020). Kentsel Hava Taşımacılığı (Urban Air Mobility-UAM) olarak adlandırılan bu yeni iş modeli ile şehir içi ve şehirlerarası ulaşımında seyahat zamanının ciddi anlamda düşmesi, çevreye uzun vadede daha az zarar verecek olması, enerji maliyetlerini azaltması ve karayollarına kıyasla daha az altyapı kaynağı gerektirmesiyle de tüketiciler açısından dikkat çekmektedir (Yedavalli ve Mooberry, 2019).

Kentsel Hava Taşımacılığı sistemi iş modeli olarak özerk, otonom ya da daha basit bir pilotaj eğitimi ile insanlı olarak kullanım kolaylığı

sağlaması, yüksek teknolojik sistemlerle emniyetli/güvenli yolculuk sunması, diğer ulaştırma modlarına kıyasla toplumu daha az negatif etkilemesi ile toplum dostu olması, elektrikli olması sebebiyle daha az enerji tüketimi, daha yüksek çevre duyarlılığı olması, ücret olarak yüksek erişilebilirliği sağlayacak bir hedef belirlenmesi, altyapı (vertiport; iniş kalkış alanları ve hava trafiği) izin verdiği sürece kapıdan kapıya ulaşım imkanı sunması ve talebe bağlı/anlık bir hareketlilik imkanı sunmasıyla tüketicileri cezbetmektedir (Straubinger vd, 2020). Havacılık sektörünün bugünü ve yakın geleceğinin en önemli gündemlerinden biri olan bu sisteme dair halihazırda var olan uygulamaları incelemek faydalı olacaktır.

İlk örnek olarak paylaşım ekonomisinin öncü girişimlerinden biri olan UBER'in yeni nesil hava taşımacılığı için Amerikan Federal Havacılık Kurulu'ndan (FAA) izin aldığı, Dallas, Los Angeles ve Melbourne şehirlerinde kendi kuracağı havalimanlarında, 2020 yılı itibariyle test uçuşlarına başladığı, 2023 yılı itibariyle profesyonel hava taksi hizmeti vermeye başlamayı planladığı belirtilirken, Uber Air adını verdiği girişimle düşük irtifada 4 kişilik hava araçlarıyla 20 km için yaklaşık 100 dolarlık bir ücretle faaliyetlerine başlayacağı, ilerleyen dönemlerde ise km başına 5 dolar olan ücretin yarıya kadar düşebileceği öngörülmektedir (Airporthaber, 2019).

Avrupalı Airbus firması geliştirdiği "Uçan Araba: Vahana" projesini 2018 yılında test ettiği bilinirken, uçan taksi prototipi CityAirbus'ın insansız (pilotsuz), 4 yolcu kapasiteli, dikine kalkış yapabilen, elektrik motorlu ve kara araçlarından ortalama 3 kat daha hızlı olacağı, 2020 yılının içerisinde ilk uçuşunu gerçekleştirdiği, 2023 yılı itibariyle de hizmete başlayacağı ifade edilmektedir (Jasper, 2019). Bir diğer dev uçak üreticisi Amerikalı Boeing ise PAV adını verdiği ve ilk test uçuşunu Ocak 2019 yılında başarıyla gerçekleştirdiği benzer özelliklere sahip hava taksi modeli ile talebe yönelik hava taşımacılığına hizmet verebilecek şekilde çalışmalarını sürdürdüğü belirtilmektedir.

Dev uçak üreticileri Airbus, Boeing ve helikopter üreticisi Bell'in çalışmalarının yanı sıra Alman havacılık şirketi Lilium da 5 yolcu kapasiteli elektrikli hava araçlarını 2025 yılına kadar kullanıma hazır hale getireceklerini ve

NASA dahil diğer tüm rakip projelere oranla çok daha uzun yolculuk yapma imkânı sunan bir hizmet vereceklerini belirtmektedirler (Airnewstime, 2019). Dünya genelindeki örneklerin Türkiye'deki yansıması olarak ilk milli uçan otomobil projesi olan "Cezeri" ilk kez Teknofest 2019'da tanıtıldığı, 2020 yılı eylül ayı itibariyle de test uçuşlarının yapıldığı modelin 3-4 sene içerisinde rekreasyon maksatlı olarak kullanımına başlanabileceği, 10-15 yıl içerisinde de kentsel hava taşımacılığı maksadıyla kullanılabilirliği aktarılmaktadır (Baykar, 2020).

Dünya genelinde bu tarz çalışmalar ve denemeler hız kazanmışken, havacılık otoriteleri de bu duruma kayıtsız kalamamış, Avrupa Havacılık Emniyeti Ajansı (EASA), 9 yolcu kapasitesi ve maksimum 3.175 kg ağırlığa kadar, dikine kalkış yapabilen (VTOL) elektrikli bu hava araçlarının emniyetli operasyonlarını yapabilmek için ilk adımı atarak sertifikasyon alabilmeleri adına 2019 yılı itibariyle özel şartları yayınlamışlardır (Garrett-Glaser, 2019).

Aviation Today isimli web sayfasında kuşaklara ve değişen havacılık sistemine yönelik bir habere göre, yaklaşık 22 bin kişi ile yapılan "Küresel Otonom Araç Çalışması" sonuçlarına göre, 18 – 24 yaş aralığındaki kişilerin %80'ni özerk/insansız hava araçlarıyla seyahate sıcak baktığı, 65 yaş üstü insanların ise yalnızca %45'inin bu süreci deneyebileceğini belirtirken genel anlamda çalışmaya katılan insanların %70'nin hayatlarının bir döneminde otonom uçuşları denemeye hazır olduğu, %58'in bunu önümüzdeki 10 yıl içerisinde yapabileceği, %12'sinin ise 10 yıldan daha uzun bir süre sonra deneyebileceği belirtilirken; Airbus firması yaptığı benzer bir çalışma ile 25 – 34 yaş arası kişilerin Kentsel Hava Taşımacılığı (UAM – Urban Air Mobility) en olumlu yaklaşan grup olduğunu belirtmektedir (Bellamy, 2019).

Kentsel Hava Taşımacılığı sisteminin iş modeli ve tüketici kabulünün başarısızlığı etkisi yadsınmaz ancak bir diğer dikkate alınması gereken husus da başarının sürdürülebilir olmasıdır. Bu anlamda Kentsel Hava Taşımacılığının konumlandırılması ve diğer ulaştırma modları ile olası rekabeti ya da entegrasyonu da önemlidir. Bu anlamda sistemin enerji tüketimi açısından kara taşımacılığına göre daha yüksek ve daha pahalı

olması ve vertiport ismi verilen iniş kalkış alanların yaratacağı kısıt sebebiyle bir toplu taşıma hizmetine dönüşmesi çok olası gözükmemektedir (Straubinger vd, 2020). Bu sebeple sistemin diğer ulaştırma modlarıyla rekabetinden daha çok verimli bir şekilde entegrasyonunun ana hedef olması düşünülmelidir. Buna örnek olarak sistem kısıtlı ulaşım sahne bölgelere (adalar, göller, nehirler gibi) erişim ya da kentiçi ulaşım seçeneklerinde en uygun alternatifin yaratılmasında karayolu taşımacılığı başta olmak üzere diğer ulaştırma modlarının tamamlayıcısı olarak faaliyet göstermesi de iyi bir çözüm olarak değerlendirilebilir (Straubinger vd, 2020).

Değerlendirme ve Sonuç

Hava taşımacılığı tarihi boyunca yaşanan ekonomik olaylar, teknolojik gelişmeler ve kültürel/sosyolojik dönüşümler havayollarının iş modellerinin belirlenmesinde etkili olmuştur. İş modelleri temel düzeyde ilk zamanlarda 'bayrak taşıyıcı' olarak adlandırılan tam hizmet sağlayıcı havayolları ve onun zorlayıcı rakibi düşük maliyetli havayolları merkezinde konumlanırken günümüzde iş modelleri bu standart zincirlerden kurtulmaya başlamıştır (Urban vd, 2018). Havayolları için iş modellerini belirlerken kullanılan parametrelerdeki yük (yolcu/kargo), ücret ya da dakiklik gibi kavramlar belirleyici kriter olmaktan ziyade iş modellerinin sonucunu yansıtırken, işletmeler açısından taktiksel, operasyonel ve stratejik karar seviyeleri iş modellerinin belirlendiği düzeyler olmalı; pazar ve sektör analizi bu karar süreçleri dikkate alınarak tasarlanmalıdır (Daft ve Albers, 2013).

Bu noktada işletmelerin sektördeki dinamik yapıya, dünyadaki ekonomik ve siyasi duruma ve talebi oluşturan yolcuların kültürel ve sosyolojik durumlarına göre hareket edebilmesi oldukça önemlidir. Yakın geçmişin ve günümüzün ekonomik dinamikleri olan paylaşım ve üyelik ekonomisi; yakın geleceğin konusu olan otonom araç teknolojisi ile Kentsel Hava Taşımacılığı bu anlamda sektör profesyonelleri açısından dikkatle takip edilmelidir.

Paylaşım ekonomisi ve üyelik ekonomisi kavramları Dünya genelinde artan şekilde ciddi bir farkındalık ve popüleriteye sahiptir. Bunun ulaşım endüstrisine yansımalarının da bir o kadar etkili ve ilgili çekici olacağı tahmin


edilmektedir. 2000 yılında ABD’de Zipcar girişimiyle beraber araç paylaşımının faaliyete geçmesinin ardından elde edilen tecrübelerle gelecekte araç sahipliğinin çok da gerekli olmadığı açıkça ortaya çıkacağı, Dünya genelinde UBER başta olmak üzere birçok girişimin önderliğini yaptığı bu paylaşım ekonomisi faaliyetinin haftalık ya da aylık gibi daha uzun vadeli kullanım sözleşmeleriyle üyelik ekonomisinin de bir yansımasını ortaya koyacağı beklenmektedir (Tzuo ve Weisert, 2018).

Dünya genelinde farkındalık az olsa da havacılık sektöründe birçok şey değişmeye başlarken, paylaşım ve üyelik ekonomisinin yansımaları da sektörün öncü örneklerinden Surf Air’in CEO’sunun da belirttiği gibi “Havacılığın Netflix’i” ya da “Gökyüzünün Uber’i” gibi dönüşümlere de başladığı ve bunun devamının geleceği de söylenmektedir (Tzuo ve Weisert, 2018).

Diğer yandan, IATA Havacılığın Geleceği:2035 raporunda sektörün ve paydaşların yüzleşmek zorunda kalabileceği ekonomik, sosyal, politik ve teknolojik unsurlara dikkat çektiği ve geniş bir perspektifte çevreden güvenliğe, ekonomiden hukuki düzenlemelere kadar 11 ana başlıkta 23 öneri sunmaktadır. Bu öneriler arasında hava araçlarının otomasyonu, havalimanlarının dönüşümü, 'hava taşıyıcıların (havayolları)' farklılaşabileceği, yolcuların değişen talepleri ve yeni iş modellerine de dikkat çekilmektedir. 2018 yılında yayımlanan bu raporda yer verdiği bilgilere göre, kısa mesafelerde ve hızlı ulaşım imkanlarında hızlı tren, drone ve insansız hava aracı firmaları gibi yeni rakiplerle mücadele etmek durumunda kalacak olan havayolu endüstrisi, daha çok uzun mesafe uluslararası uçuşlara odaklanmalı ve otomasyon ve yeni iş modellerinin sağlayacağı avantajlarla kalabalık “hub” denilen merkez havalimanı fikrinden uzaklaşarak noktadan noktaya fikrine uygun ikincil ve daha küçük havalimanları operasyonlarını dikkate almalı; “Uber tipi iş modelleri” gibi yaklaşımlarla yeni intermodal bağlantılar kurabilmelidir (Steele, 2018:32).

Dünyada tüm sektörlerin yüzleşmek zorunda kaldıkları 2019 sonunda raporlanan ve 2020 yılını etkisi altında alan Covid-19 salgını gibi beklenmeyen olayların havacılık sektörünün gelecek hedeflerini farklı yönlere sürüklemesi mümkündür. Coronavirüs (Covid-19) salgını

sonrası başta ABD olmak üzere dünya genelinde havacılık sisteminde bir daralmaya gidileceği, bunun şirketler açısından merger denilen birleşme/satın alma vb. sonuçlar doğurabileceği, çalışanlar açısından iş kaybı ile sonuçlanma ihtimalinin yüksek olduğu, yolcular açısından ise düşük maliyetli taşıyıcıların sunduğu avantajları artık yakalayamayabileceği, daha az uçuş ve frekans seçeneği ile karşılaşabileceği ve bu uçuşlara daha yüksek fiyatlar ödemek zorunda kalabileceği belirtilmektedir (Isidore, 2020). İlâveten, Covid-19 salgını sonrasında daha küçük uçak/operasyonlar fikrinin yeniden ön plana çıkacağını öne sürmektedir (Meyer, 2020). Bu durum da geleneksel havayolu iş modellerinin zorunlu bir dönüşüm yaşamak durumunda kalabileceği dair bir ipucu olarak tüketiciler ve profesyoneller tarafından değerlendirilmelidir. Buna bir örnek olarak Şekil 10'da verilen grafikte gösterildiği üzere tarifeli uçuş sayısında Covid-19 ile birlikte çok ciddi bir düşüş yaşanmış ve toparlanma hala gerçekleşmemiştir. Bu durumda aslında havacılık sektörü ve havayolları için olumsuz özelliklerinden ayrı olarak yeni bir yenilenme, yapılanma fırsatı olarak da görülebilir. Bu tahmin de paylaşım ve üyelik ekonomisi odaklı iş modelleri ve bu modellerin gelecek yansıması olarak değerlendirilebilecek kentsel hava taşımacılığı modellerinin olasılığını destekleyen bir unsur olarak öne çıkmaktadır.



Şekil 10: Covid-19'un Tarifeli Uçuşlar Üzerine Etkisi

Kaynak: URL6

Havacılık sektörü geleneksel iş modellerin dönüşümünün yanı sıra dördüncü endüstriyel devrim ile başta dijitalleşme olmak üzere yeni dönüşümler ve adaptasyon süreçleriyle de meşgul olmak durumunda kalmıştır. Havacılık 4.0 olarak adlandırılabilir bu süreçte havacılık sektörü dijitalleşme, yeni teknolojiler, otomasyon, pil/enerji teknolojisi,

gürültü/emisyon, havaaracı performansı, pilotaj eğitimi, tüketici talepleri, trafik sıkışıklığı gibi hem yeni endüstriyel devrimin getirdikleri hem de geleneksel problemlerle bir arada yüzleşmek zorundadır (Cokorilo, 2020). Bu sebeple de havacılığın geleceği adına yeni çalışmalar ve girişimler ortaya konmaktadır.

Buna örnek olarak çeşitli girişimler ve Boeing, Airbus, Uber, Toyota ve Hyundai gibi dev firmaların da üzerine çalıştığı Kentsel Hava Taşımacılığı sisteminin 2030 yılı içerisinde olgunluğa ulaşması ve dünya genelinde bir patlama yapacağı, 2040 yılı itibariyle 1,5 milyar dolarlık bir paya sahip olması beklenmektedir (Hornyak, 2020). Aynı çalışmaya göre yaklaşık 300 km hızla 1.000 – 2.000 feet irtifada yapacağı operasyonlarla kent içi trafik karmaşasını rahatlatması hedeflenirken, 2022 yılı itibariyle Dubai'de başlaması ve 2040 yılına kadar büyük bir sıçrama yapması beklenmektedir (Hornyak, 2020). Bu tahminler de hem sektördeki paydaşların hem de tüketicilerin sektörde bir yeniliğe ihtiyacı olduğunun farkında varması ve bunu kabullenmesi ile ilişkilendirilebilir.

Sonuç olarak günümüzde paylaşım ve üyelik ekonomisi modellerinin ve gelecekte de kentsel hava taşımacılığı iş modellerinin sektörün uygulamalarında karşımıza çıkması muhtemel modeller olarak değerlendirilmektedir. Ticari havayolu taşımacılığı sektörünün mevcut haliyle bir doyumluğa ulaştığı ve uçuş hizmeti süresince yapılan/farklılaşan pazarlama faaliyetleri dışında tüm havayolu işletmelerinin özünde aynı hizmeti verdiği yolcular tarafından da açık şekilde bilinmektedir. Sektörün Covid-19 salgınıyla sektöre uğrayan yükseliş ivmesi düşünüldüğünde, bu ivmenin daha da sürdürülebilir olması adına farklı iş modellerinin ön plana çıkması gerektiği düşünülmektedir. Ayrıca Covid-19 ile yaşantımızın bir parçası olmaya başlayan daha izole, daha mesafeli yaşam gibi yeni alışkanlıkların da yeni iş modellerinin gelişiminde etkisi olabileceği düşünülmektedir. Diğer yandan sektörün tüm bu yaşananlar çerçevesinde bir duraksama döneminde olduğu kabul edilirse, yakın geçmişte hayatımıza giren Endüstri 4.0 ve kavramları da yeniden doğuş için iyi bir fırsat olarak değerlendirilebilir. Özellikle karayolu taşımacılığında başarılı örnekleri tüketicilere sunulmaya başlanan otomasyon araçların ve dijital teknolojilerin, Kentsel Hava Taşımacılığı ismi ile anılan

havacılık sektörü yansımaları da bu açıdan önemle takip edilmelidir. Gelecek çalışmalarda yukarıda değinilen tüm iş modelleri ve stratejilerinin yolcular açısından değerlendirileceği bir çalışmanın yapılmasının hem literatüre hem de sektöre ciddi katkı veren bir adım olacağı öngörülmektedir.

Araştırmacıların Katkı Oranı Beyanı

Çalışma, ikinci yazarın danışmanlığında birinci yazar tarafından yazılan doktora tezinden üretilmiştir.

Destek ve Teşekkür Beyanı

Çalışma herhangi bir destek almamıştır. Teşekkür edilecek bir kurum veya kişi bulunmamaktadır.

Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

Referanslar

Airnewstimes, “Hava Taksi Seferleri 2025 Yılına Kadar Başlayacak”, www.airnewstimes.com/hava-taksi-seferleri-2025-yl-na-kadar-baslayacak-48422-haber.html, 10.10.2019.

Airporthaber, “Uber'in Hava Taksi Merkezi Böyle Görünecek”, <https://www.airporthaber.com/havacilik-haberleri/uberin-hava-taksi-merkezi-boyle-gorunecek.html>, (09.08.2019)

Al Haddad, C., Chaniotakis, E., Straubinger, A., Plötner, K., & Antoniou, C. (2020). Factors affecting the adoption and use of urban air mobility. *Transportation research part A: policy and practice*, 132, 696-712.

Alexander D. Ve Natarajan, B. (2017). “The Future Of Air Travel: Eight Disruptive Waves Of Change. The Road To, 2025”. <https://www.cognizant.com/whitepapers/the-future-of-air-travel-eight-disruptive-waves-of-change-codex2566.pdf>, 08.06.2018

Baykar, “Türkiye'nin İlk Uçan Arabası Cezeri Havalandı”, <https://www.baykarsavunma.com/haber-turkiyenin-ilk-ucan-arabasi-cezeri-havalandi.html>, 22.09.2020

Baxter, R. K. (2015), *The Membership Economy: Find Your Super Users, Master The Forever Transaction, And Build Recurring Revenue*, Mcgraw Hi Education.

Bellamy W. (2019), *Millennials Ready To Embrace Autonomous Aircraft*, *New Global Study Finds*, <https://www.av-at-ontoday.com/2019/06/20/millennials-ready-embrace-autonomous-airplanes-new-global-study-finds/>, 03.04.2020

Budd, L., & Ison: (Eds.). (2020). *Air Transport Management: An International Perspective*. Routledge.

Cokorilo, O. (2020). Urban air mobility: safety challenges. *Transportation research procedia*, 45, 21-29.

Corbo, L. (2017). “In Search Of Business Model Configurations That Work: Lessons From The Hybridization Of Air Berlin And Jetblue”. *Journal Of Air Transport Management*, 64, 139-150. <https://doi.org/10.1016/j.jairtraman.2016.09.010>

Cummins, N. (2019). *Would A Subscription Airline Model Work?* Retrieved From Simple Flying Website: <https://simpleflying.com/airline-subscription-model/>, 02.04.2020

Demirer, D., & Hassan, A. (2016). “Değiş Tokuş Ve Kiralama Uygulamalarının Konaklama İşletmeleri Üzerindeki Olası Etkileri. *Anatolia*”: *Turizm Araştırmaları Dergisi*, 27(1), 43-61.

Deutsches Zentrum Für Luft- Und Raumfahrt (Dlr). (2008). *Airline Business Models*. 44. https://ec.europa.eu/transport/sites/transport/files/modes/air/doc/abm_report_2008.pdf

Dewalska-Opitek, A. (2017). *Generation Y consumer preferences and mobility choices—an empirical approach*. *Archives of Transport System Telematics*, 10.

Di Vito, V., Torrano, G., Cerasuolo, G., & Ferrucci, M. (2021, April). *Conceptual Design of A Pilot's Decision-Making Support System for Tactical Separation of Small Air Transport Vehicles in Future Sesar ATM Environment*.

In 2021 Integrated Communications Navigation and Surveillance Conference (ICNS) (pp. 1-13). IEEE.

Flouris, T. G. Ve Oswald: L. (2006). Designing And Executing Strategy İn Aviation Management. Ashgate Publishing, Ltd.

Garrett-Glaser B. (2019), Easa Releases Special Condition For Certifying Electric, Hybrid Vtol Aircraft, https://www.rotorandw.ng.com/2019/07/03/easa-releases-spec_al-cond_t_on-cert_fy_ng-vtol-a_rcraft/, 14.01.2020.

Gerede, E. (2015). Havayolu Taşımacılığı Ve Ekonomik Düzenlemeler Teori Ve Türkiye Uygulaması. Art Ofset Matbaacılık, Ankara.

Hornyak, T. (2020). The Flying Taxi Market May Be Ready For Takeoff, Changing The Travel Experience Forever. Retrieved From <https://www.cnbc.com/2020/03/06/the-flying-taxi-market-is-ready-to-change-worldwide-travel.html>, 05.05.2020

ICAO International Civil Aviation Organization. (2004). Doc 9626, Manual On The Regulation Of International Air Transport - Second Edition.

IHLG, Industry High Level Group (2019). Aviation Benefits Report 2019., <https://www.icao.int/sustainability/Documents/Aviation-Benefits-2019-Web.Pdf>, 12.02.2020

ICAO. (2020). Effects Of Novel Coronavirus (Covid-19) On Civil Aviation: Economic Impact Analysis Air Transport Bureau Contents. (June). Retrieved From https://www.icao.int/sustainability/Documents/Covid-19/Icao_Coronavirus_Econ_Impact.Pdf,

ICAO (2021). Future of Aviation, <https://www.icao.int/Meetings/FutureOfAviation/Pages/default.aspx>, (Erişim tarihi: 18.08.2021)

Isidore, C. (2020). Airlines Will Offer Fewer Choices And Higher Fares After The Coronavirus Crisis. Retrieved From <https://edition.cnn.com/2020/04/01/business/airline-industry-outlook/index.html>

Jasper C. (2019), Airbus's Flying Taxi Is Poised For Takeoff Within Weeks, <https://www.bloomberg.com/news/articles/2019-01-23/airbus-s-fly-ng-taxi-s-poised-for-takeoff-within-weeks>, 08.03.2020

Klophaus, R., Conrady, R., & Fichert, F. (2012). "Low Cost Carriers Going Hybrid: Evidence From Europe". Journal Of Air Transport Management, 23, 54-58.

Linz, M. (2012). "Journal Of Air Transport Management Scenarios For The Aviation Industry : A Delphi-Based Analysis For 2025". Journal Of Air Transport Management, 22, 28-35.

Lohmann, G., & Koo, T. T. R. (2013). "The Airline Business Model Spectrum". Journal Of Air Transport Management, 31, 7-9.

Mccarthy, D. M., Fader, P. S., & Hardie, B. G. S. (2017). Valuing Subscription-Based Businesses Using Publicly Disclosed Customer Data. Journal Of Marketing, 81(1), 17-35.

McNutt, E. (2016), Trying Out Onego., The "Unlimited Flying" Subscription Service, <https://thepointsguy.com/2016/02/unlimited-fly-ng-w-th-onego/>, 17.05.2019.

Martínez-González, J. A., Parra-López, E., & Barrientos-Báez, A. (2021). Young Consumers' Intention to Participate in the Sharing Economy: An Integrated Model. Sustainability, 13(1), 430.

Meyer, D. (2020). After Coronavirus, Expect To See Smaller Airlines. Retrieved From <https://fortune.com/2020/04/09/lufthansa-airlines-smaller-after-coronavirus/>, 12.07.2020

Ozkan E., Özel Havacılıkta Paylaşım Ekonomisi, <https://www.airnewstimes.com/Ece-Ozkan-Ozel-Havacilikta-Paylasim-Ekonomisi-715-Yazisi.Html>, Erişim: 20.09.2020

Pereira, B. A., & Caetano, M. (2015). A conceptual business model framework applied to air transport. Journal of Air Transport Management, 44, 70-76.

Porter, M. E. (1996). “What Is Strategy?” *Harvard Business Review*, 74(6), 61–78.

Richter, C., Kraus, & Syrjä, P. (2015). “The Shareconomy As A Precursor For Digital Entrepreneurship Business Models”. *International Journal Of Entrepreneurship And Small Business*, 25(1), 18.

Roh, T. H. (2016). “The Sharing Economy: Business Cases Of Social Enterprises Using Collaborative Networks”. *Procedia Computer Science*, 91(Itqm), 502–511.

Sabella, R., Iovanna, P., Bottari, G., & Cavaliere, F. (2020). Optical transport for Industry 4.0. *Journal of Optical Communications and Networking*, 12(8), 264-276.

Sheehan, J. J. (2003). *Business And Corporate Aviation Management. On-Demand Air Transportation.* Mcgraw-Hill Professional

Steele, P. (2018). Future Of The Airline Industry 2035. Retrieved From <https://www.ata.org/policy/documents/ata-future-airline-industry.pdf>, 23.03.2020

Straubinger, A., Rothfeld, R., Shamiyeh, M., Büchter, K. D., Kaiser, J., & Plötner, K. O. (2020). An overview of current research and developments in urban air mobility—Setting the scene for UAM introduction. *Journal of Air Transport Management*, 87, 101852.

Tzuo, T., & Weisert, G. (2018). *Subscribed: Why The Subscription Model Will Be Your Company's Future-And What To Do About It.* Penguin.

Urban, M., Klemm, M., Ploetner, K. O., & Hornung, M. (2018). Airline categorisation by applying the business model canvas and clustering algorithms. *Journal of Air Transport Management*, 71, 175-192.

URL1, Netjets, <https://www.netjets.com/en-us/>, (Erişim tarihi: 03.09.2020)

URL2, Vistajet, <https://www.vistajet.com/en-gb/empty-legs/>, (Erişim tarihi: 03.09.2020)

URL3, Avinode, <https://www.avinode.com/>, (Erişim tarihi: 03.09.2020)

URL4, Wingshare, <https://www.wingshare.fr/>, (Erişim tarihi: 03.09.2020)

URL5, Helipass, <https://www.helipass.com/en/>, (Erişim tarihi: 3.09.2020)

URL6, https://www.oliverwyman.com/content/dam/oliver-wyman/v2/AEA%202021_Master_Final2.pdf, (Erişim tarihi: 18.08.2021)

URL7, <https://www.icao.int/Meetings/FutureOfAviation/Pages/default.aspx>, (Erişim tarihi: 18.08.2021)

Wang, Z. (2009). *The Impact Of Pricing On Supply Chain Performance Measurement.* The University Of Wisconsin-Milwaukee.

Wensveen, J. (2016). *Air Transportation: A Management Perspective.* Routledge.

Xiang, J., Ogata, K., & Futatsugi, K. (2007). “Analysis Of Membership Sharing In Digital Subscription Services”. *International Journal Of Revenue Management* 3(3):284-306

Yedavalli, P., Ve Mooberry, J. (2019). An Assessment Of Public Perception Of Urban Air Mobility (Uam). *Airbus Utm: Defining Future Skies*, 1–28.

Review Article

Smart Diagnosis and Maintenance Systems for Railway Tracks

Erdem Balcı^{1,*}, Ertan Yalçın², Tunay Uzbay Yelce², Niyazi Özgür Bezinçin³

^{1,2,3} Civil Engineering Department, Engineering Faculty, Istanbul University-Cerrahpaşa, Istanbul, Turkey

^{1*} Construction Department, Alaplı Vocational School of Higher Education, Bülent Ecevit University, Zonguldak, Turkey

*Correspondence: erdembalci@outlook.com

DOI: 10.51513/jitsa.951322

Abstract: In recent years, advanced technologies such as artificial intelligence (AI), the internet of things (IoT), and big data came into prominence. These technologies found an extensive area of utilization in various sectors. Railway systems as an important part of the transportation of people and goods should be improved by the integration of novel technologies. Successful detection of track faults and operating maintenance tasks accordingly are essential for the safety of railway operations. Currently, image processing and pattern recognition via machine learning applications are in common use for automated track inspections. However, it is not possible to claim that railway tracks are integrated with current technology perfectly. In this work, differences between the traditional way and the smart way of track inspection and maintenance are presented. Shortcomings of the application of advanced technologies into railway tracks are detected and required actions for further improvements are discussed. Lastly, the effects of the use of smart systems on the life cycle of the structures are evaluated.

Key words: Railway track, track inspection, track maintenance, artificial intelligence, machine learning

Demiryolu Hatları İçin Akıllı Teşhis ve Bakım Sistemleri

Özet: Son yıllarda yapay zeka (AI), nesnelerin interneti (IoT) ve büyük veri gibi ileri teknolojiler ön plana çıkmaktadır. Bu teknolojiler çeşitli sektörlerde geniş bir kullanım alanına sahiptir. İnsan ve yük taşımacılığının önemli bir parçası olan demiryolu sistemleri, bu yeni teknolojilerin entegrasyonu ile iyileştirilmelidir. Hat arızalarının başarılı bir şekilde tespiti ve bu tespitlere göre yapılan hat bakımları, demiryolu işletmesinin emniyeti için gereklidir. Şu anda, görüntü işleme ve makine öğrenimi yardımıyla örüntü tanıma uygulamaları, otomatik hat denetimleri için yaygın olarak kullanılmaktadır. Ancak demiryolu hatlarının günümüz teknolojisiyle mükemmel bir şekilde entegre olduğunu söylemek mümkün değildir. Bu çalışmada, geleneksel ve akıllı teşhis ve bakım yöntemleri arasındaki farklara yer verilmiştir. İleri teknolojilerin demiryolu hatlarına uygulanmasındaki eksiklikler tespit edilmiş ve daha iyi bir gelişim için gerekli eylemler tartışılmıştır. Son olarak, akıllı sistemlerin kullanımının, yapıların yaşam döngüsü üzerindeki etkileri değerlendirilmiştir.

Anahtar Kelimeler: Demiryolu hattı, hat denetimi, hat bakımı, yapay zeka, makine öğrenimi

1. Introduction

The use of information, digital, and telecommunication technologies enhanced the flexibility, efficiency, and sustainability of the services for inhabitants good in smart cities (Mohanty et al, 2016). The cooperation of two closely related fields, i.e. internet of things (IoT) and big data is the key for responsive, efficient, friendly, and advanced smart cities. IoT is the inclusion of “things” to the communication by mixing physical and virtual worlds together and enabling information transfers between humans and things and/or between things themselves (Tan and Wang, 2010). “Things” are smart tools such as sensors that collect data from their environment to raise awareness about the context.

The size of the data produced by the sensors is enormous. It is discussed in terms of petabytes

and continuously increasing with the installation of more data-generating tools. The type of data produced by the sensors can be unstructured, semi-structured, or structured. Collective big data contains data sets that frequently used software can not capture, organize, manage, and process the data within a tolerable elapsed time (Snijders et al, 2012). Data analytics consists of descriptive, diagnostic, predictive, and prescriptive analytics. Figure 1 shows the steps from gathering data from sources to the evaluation of them in the operations. Big data analytics can be achieved through the use of artificial intelligence (AI) techniques such as machine learning, natural language processing, data mining, etc., and thence, one can develop an understanding from the raw data. This makes system performance optimization, product improvements, and better business decisions possible.



Figure 1. Process of data management

Railway operations aim to achieve various goals at the same time: Providing safe, economical, fast, and comfortable transportation. New technologies allow us to not only satisfy minimum requirements but also improve track conditions further and optimize track performance. However, some concerns are raised about the implementation of advanced technologies into railways. Challenges are either railway application-specific or originated from the nature of big data use.

In this study, the degree of the integration of advanced technologies into the railway tracks is investigated. Studies of the literature about railway track applications of IoT, big data, and various artificial intelligence (AI) techniques are examined. While there are various ways of implementing discussed technologies into rail transport systems, smart monitoring and maintenance systems come to the forefront in terms of benefiting from track mechanics data to optimize performance and enhance the safety and life cycle of the track. The paper determines the shortcomings of smart track monitoring tools and provides a new direction of research

for more advanced railway track monitoring. Also, it analyzes the significant effect of the proper monitoring and maintenance decisions on the sustainability of the structures.

2. Traditional way of track maintenance

Safety is the essential and serious theme of railway transportation. Railway tracks must be designed to meet safety criteria as well as maintaining acceptable track conditions, however, geometry and structural defects may occur under the repeated wheel loads over their service lives. Detection and adjustment of railway defects via a regular maintenance plan is crucial for the safety and also economical benefits of the railway track. In the United States only, rail defect-related accidents caused a \$108.7 million loss, constituting %34.8 of the total train accidents in 2009 (Peng, 2011). In the Netherlands, it is estimated that railway track maintenance constitutes half of the maintenance budget each year (Zoeteman et al, 2014). Therefore, a maintenance plan is necessary for enterprises to accurately predict the changes in track conditions so that they may guarantee the economical advantage of the track.

Track quality conditions can be simply measured by the track quality index (TQI). Equation 1 presents the formulation of a basic linear model for TQI prediction proposed by Shanghai Railway Bureau, Weichang Xu. represents initial TQI, K represents the deterioration rate, and T is the total accumulated weight. This model can simply predict the short-term changes in TQI, however, relatively larger deviations occur in the long-term because track degradation is not only based on the total weight but also geographical location, temperature, precipitation, measurement errors, and so on (Song et al, 2014) Besides, one must know the probable rate of track deterioration to use the given formula. However, the literature review of Melo et al. (2020) reveals that currently there is no track deterioration method available to analyze the condition of the track (Andre et al, 2020) Their extensive survey detected more than 100 studies related to track deterioration but most of the methods can not be used when several track deteriorations occur.

$$TQI = TQI_0 + K * T \quad (1)$$

Currently, special track inspection curs run 2-4 times a year to gather data from the track. Repairment decisions are made by comparing track obtained irregularity data with the limits specified in the regulations such as EN 13848-5 which specifies track gauge and longitudinal level values for various train speeds (EN 13848-5:2008+A1:2010). For instance, if the mean to the peak value of the level difference in the track data is 7-12 mm for the wavelength of 20 m and train speed of 200 km/h, it is the alert limit that requires the track geometry condition to be analyzed and considered in the regularly planned maintenance operations. Likewise, 9-14 mm is the intervention limit that requires corrective maintenance, and 20 mm is the immediate action limit that requires taking immediate actions against the risk of derailment. AREMA guides the railway experts through comparison of the strip chart output of Track Geometry Measuring Vehicle (TGMV) with predetermined thresholds set by railway administrators to evaluate the condition of the track (AREMA, 2016). Interestingly, threshold criteria for maintenance decisions have not changed in about 50 years (Yokoyama, 2015).

DEFECT NAME	FROM POST/FEET	TO POST/FEET	LENGHT(FEET)	MAXIMUM VALUE	THRESHOLD	SPEED	TRACK TYPE
L PROFILE	47 + 678	47 + 685	7	3/4	5/8	60	T
R PROFILE	47 + 678	47 + 685	7	3/4	5/8	60	T

Table 1. An example of strip chart produced by TGMV (AREMA, 2015)

Constantly evolving data-driven methods, on the other hand, may help to achieve smart management decisions. Big data in railway track maintenance is the vast amount of train and test data gathered from the track and used for the track condition evaluation. This can also help to perceive the equipment condition rapidly, tracing all historical data and obtaining a specific historical condition of the equipment. Data-driven track diagnosis can be achieved by implementing machine learning (ML) algorithms. In the next chapter, the foundation of the AI-based evaluation: ML will be overviewed. In the following chapter, shortcomings of the smart diagnosis and maintenance systems in the railway tracks will be discussed. Lastly, the effects of smart maintenance on the sustainability of railway

tracks will be examined by analyzing their life cycle costs.

3. Overview of machine learning

Machine learning is a trending branch of AI, that builds a mathematical model based on the collected data to make predictions and decisions without being programmed. In this chapter, data types, ML learning methods, algorithms, and data analysis methods will be introduced briefly.

ML applications consist of three types of data: train, test, and validation data. ML algorithms use trained data to create a mathematical model. The ultimate goal is the training the model with the train data to produce the results that give the correct answers to questions as much as possible. Most of the collected data is used as

train data (%60-90). After, the created model is tested with the test data. The results of the trained data are removed and the machine is allowed to make predictions. Estimates and actual outputs of the data are compared. Test data determines the accuracy of the predictions and measures the performance of the algorithms. With the validation data, the trained model is tried to be improved. For this, the most optimum coefficients are found by trying hyperparameter tuning applications. In a dataset with very large data, 15-20% of the data is used for validation, since train or test data can not be used for this development.

There are two learning methods that ML applications use for training. In supervised learning, inputs and outputs are known in the dataset, so that the model can be trained by building relationships between input and outputs of the data. Supervised learning can be used for railway management. The numbers and condition of the line, the effect of the traffic level that may occur in certain hours and days on the arrival time of the train from one place to another can be measured on the basis of time. By correlating all (input) variables with the travel time parameter (as output), a model can be created to make predictions about the travel time of a train. A few of the most frequently used supervised learning algorithms can be listed as follows:

- *Decision Trees*: It is used to divide a data set into smaller sets according to certain rules. However, overfitting can be problematic in the decision tree.
- *Random Forest*: In these algorithms, multiple decision trees are created. Then, it is tried to find the right way.
- *Logistic Regression*: It is a regression where there are two possibilities. For instance, True or False; 0 or 1.
- *Neural Nets*: There are algorithms that use large amounts of training data to identify correlations between many variables to learn how to manipulate future *data*.

The second type of learning is unsupervised learning in which there are only inputs and no outputs. In this type of learning, the relationship between inputs is determined. After, data samples can be categorized based on the similarities of their input data. For instance, collected data from railway tracks can be

evaluated and clustered according to their importance (predictive maintenance). Some of the unsupervised learning algorithms are as follows:

- *K-means*: It is an algorithm to classify data in a data set into k different predetermined sets.
- *DBScan*: It is an algorithm used to distinguish between high-density clusters and low-density clusters.
- *Expectation Maximization*: It is an algorithm used to perform the highest probability estimation with unobservable variables.

Since ML applications are built on sample data, it is necessary to collect big amounts of data and prepare them for the training. The quality of the data determines the quality of the model. This is where data analysis comes into prominence. Data analysis consists of 5 main steps. These steps can be listed as follows:

1. *Defining the question*: Firstly, it is necessary to determine the problem encountered so that a hypothesis can be created by asking the right questions.
2. *Collecting the data*: There are various types of data such as numerical data, images, audio, and questionnaires. Seize and quality of the data determines the quality of the solution. Thus, data must be collected using various techniques and different datasets can be merged if required.
3. *Processing the data*: Collected data do not make sense at first. These raw data need to be made suitable for analysis. This can be achieved by data cleaning and data manipulation. Data manipulation is the whole process of making the data suitable for use without destroying its content. It has 4 main steps:

a. *Data Cleaning*: There may be inaccuracies and/or inconsistencies in the data collected. This inconsistent data is removed in this process. Various deletion techniques can be applied when there are missing values in the data. If a list contains one or more missing values, listwise deletion is applied by removing all data for that list. Usually, this is a disadvantage. It is possible to produce biased parameters and estimates. Column deletion is the process of deleting a feature in the data. It is not generally preferred, but if the number of missing data in the same variable is more than 2/3, this variable can be removed from the dataset. In pairwise deletion, the needed

variables are selected and the missing data are deleted and analyzed.

b. Data Integration: Gathering data from different sources is called data integration. Some data may have been entered several times during this integration. Data with the same inputs and outputs must be entered as single data. Missing values can be also imputed instead of being deleted. It can be filled with the value above or below the field in which the missing data is located in the column. Another favorable way to the imputation of the missing data is to use the means, median, and mode of the variable. By using the mode, the missing data can be filled with the value according to the highest frequency. Also, linear regression can be used. Missing data can be estimated by defining the column containing the missing values as the dependent variable and the other columns as the independent variable. The disadvantage is that it will be filled according to other variables, so there may be overfitting in the dataset. Lastly, imputation with categorical data can be applied. Then, missing data can be labeled and prepared for analysis.

c. Data Transformation: The collected data may not be in the desired format. This step is applied to convert these undesired formats to the format of the target format.

d. Data Reduction: Data reduction is the process of reducing the required storage capacity. This increases storage efficiency and lowers storage costs. It is the reduction of dimensions.

4. Analyzing the Data: Once the collected data is processed properly, it is ready for analysis. There are 4 types of data analysis:

a. Descriptive Analysis: It examines the data and determines what happened. It is the step before proceeding with detailed examinations.

b. Diagnostic Analysis: It focuses on understanding why an event occurred.

c. Predictive Analysis: It is an analysis method that enables the prediction new results based on past data.

d. Prescriptive Analysis: It is a type of analysis that plays a role in determining the actions to be taken for the future.

4. Smart track diagnosis & maintenance

Smart track diagnoses and maintenance systems are achieved through the integration of advanced technologies into railway tracks such application of IoT for data collection and using ML algorithms for data analytics. Railway track monitoring systems can be both track-side or on-board systems. Track-side monitoring is achieved by the mounted sensors around the track to detect the wheel profile irregularity, dynamic impact forces, and evaluate bogie performance. However, this method allows monitoring at only selected positions. On-board monitoring systems, on the other hand, mostly focus on the real-time detection of rail defects. Sensors carried on the vehicles gather information about the response of the vehicle to track excitation and component faults such as acceleration, rotation rate, displacement, noise, and temperature (Chunsheng et al, 2017). They typically include accelerometers, gyros, noise detectors, and GPS.




Figure 2. An example of an on-board rail corrugation detection system (Hayashi et al, 2006)

There are various non-destructive methods to be used for rail defect inspection such as ultrasonic

devices, high-resolution video cameras, 3D-laser cameras, and eddy current inspection.

Results of the survey conducted by Nakhaee reveal that the most popular data source for ML applications is video cameras (Nakhaee et al, 2019). Video cameras located on the measurement trains capture high-resolution images from the track from different angles. The collected data can be separated to train and test data. A model can be trained via ML algorithms and tested afterward. Such being the case, anomalies in the rail track can be detected via the created ML model.

The Research and Development Center of JR East Group has presented the “Smart Maintenance Initiative” which is defined as “21st-century innovation in the maintenance of railway equipment” (Yokoyama, 2015). This

initiative has 4 fundamental components: 1) Achieving condition-based maintenance (CBM), 2) Introduction of asset management, 3) Maintenance work support by AI and 4) Integrated database. CBM means transformation from the traditional philosophy of maintenance, e.g. time-based maintenance to performance-based planning. With more data, it is possible to perceive the trend of the deterioration better and predict the future irregularity, thus, make better decisions for maintenance by finding optimal repairment time. CBM allows daily and dynamic basis inspection so that more data can be gathered. Figure 4 presents the difference between time-based management (TBM) and CBM.

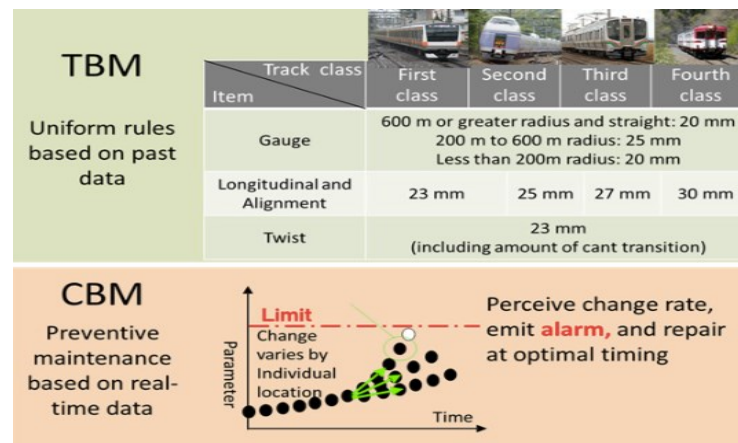


Figure 3. Comparison of traditional TBM and innovative CBM (Yokoyama, 2015)

Asset management aims to make optimal maintenance plans for the lifespan of the track. Work support by AI aims to organize an environment where humans and AI work collaboratively. The process begins with the presentation of gathered data by data scientists and then continues with the interpretation of the results by both experts of the field and AI algorithms. Therefore, storage of the data, integration of databases, and hiring skilled data scientists come into prominence as well as improving the existing AI algorithms. Smart, more frequent, and proper detection of faults increases the sustainability of the structure by contributing to the extension of its life cycle. Thus, smart diagnosis and maintenance systems for the railway tracks suit the goal of developing smart and sustainable cities of the future. However, the literature review of the existing smart railway track applications showed some challenges to overcome for full integration of the discussed technologies and thus, to provide

better performance. In the below chapter, the most mentioned problems of the literature are listed and explained.

5. Shortcomings of the integration

The cause of a system failure or an accident is now currently identified by experts in the field. Since experts are expected to have the background knowledge and sufficient experience, it is their job to find the causes and offer solutions. However, there may be a knowledge gap in a specific area, or the company may have relatively inexperienced engineers, and making a proper decision may not be possible. Maintenance engineers may take advantage of AI algorithms since they have the potential to solve complex problems and they constantly advance like an engineer who gains experience over time. Machine learning, text mining, and natural language processing can be used to develop AI experts. However, human language is a still complex issue for

computers and NLP techniques must be developed further especially in common sense-based reasoning, conversation support, and context awareness areas (Kugurakova et al, 2015; Balci, 2019).

The use of IoT produces a large volume of data that must be stored, managed, and operated. These stages require effort and also storage of the data can be sometimes problematic. Thus, companies must invest in data centers, hire skilled data scientists and personnel should work collaboratively to get the most out of the data. For example, video cameras collect approximately 10 terabytes of image data in the Dutch railway system each year (Jamshidi et al, 2017). Another challenge is the quality of the data; images may not be clear, resulting in inaccurate training of the model. The existence of oil and dust residuals can affect the performance of ML-based training negatively (Santur et al, 2016).

As a general rule, large datasets can provide better results for ML training. Large datasets are generally created by combining multiple datasets. Thus, publicly available and labeled datasets can enhance the performance of railway tracks ML applications. However, very small numbers of datasets that include rail track data are publicly available, since companies and government bodies prefer to keep data for themselves. Sharing datasets publicly or supporting ML researches in universities will allow the contribution of academics and independent researchers to the field. Labeled data is another issue since captured data through inspection are mostly not labeled. There are some studies where researchers labeled the data manually (Raghih et al, 2016; Jamshidi et al, 2018). However, for more efficient use of ML-based applications, auto-labeling systems must be developed.

Attoh-Okine (2014) determined 5 main challenges for big data use in railway engineering (Attoh-Okine, 2014): Heterogeneity, inconsistency, and incompleteness, merging data, timelines, and privacy and data ownership. Firstly; rail defect, track geometry, and tonnage data are not homogeneous. Secondly, data collection tools do not always provide certain, complete, and accurate data. Missing values reduce the success of the models. Merging data is another challenge because healthy big data analytics not

only requires large datasets but also the merging of different databases. However, in railway applications, it may not be always possible. For instance, if one has ballast condition data and also track geometry or operational data, he or she can not take advantage of these two datasets, since they do not offer standardized values. Another challenge is that efficient and effective implementation of timely maintenance sets a time limit for real-time data analytics. Finally, any electronic information such as electronic ticket info brings privacy worries.

6. Effects of smart inspection systems on the sustainability of the structures

Big data gathered by the smart sensors contributes not only to the environmental development process of the smart and sustainable transport systems but also to understanding, evaluation, and planning of them. There are already IoT integrated big data applications and smart-sustainable initiatives in some of the ecologically and technologically advanced cities (Al Nuaimi et al., 2015; Bibri and Krogstie, 2016, 2017a, 2017b, 2017c; Tokody et al., 2015). In below, some of the studies which attempt to make railway tracks smarter are shown, and later, some of the studies that show the effect of the digital transformation on sustainability are cited.

Jo et al. (2018) suggest that IoT is a fundamental enabler of the CBM in order to make the maintenance period more efficient. Even though IoT may be costly, railway maintenance can be a great business model for the implementation of IoT. However, various communication schemes and circuit design schemes must be adopted to achieve low power consumption and higher reliability (Baker et al., 2015; Kelly et al., 2013; Martinez et al., 2015; Baker et al., 2013; Kuila and Jana, 2013). Continuously advancing technology of the smart sensors has given rise to miniaturized devices with new signal processing methods, higher performance, and higher speed electronic circuits (Bibri, 2015). Castillo-Mingorance et al.'s (2020) study shows that advanced but simple sensors are able to measure diverse parameters such as deformations, vibrations, track oscillations, and dynamic impact forces. Fiber optic sensors are among the most versatile sensors, however, they have a higher cost compared to alternatives. Edwards et al. (2021) offered a concept design to

improve safety and respond to maintenance-related concerns of the track infrastructure by monitoring and estimating track health. IoT is a suitable technology for the sustainability development of railways since remote monitoring will result in faster troubleshooting and issues identification.

Johansson and Reim (2019) conducted 26 35-to-80 min interviews with a digital railway maintenance development company and the traffic agency in order to find out the outcomes of the transition to eMaintenance. It has found that implementation of eMaintenance leads to advanced information on condition, enhanced capacity, more efficient maintenance, optimized costs, and also increased sustainability. Kaewunruen and Lian (2019) developed a 6D BIM of railway turnout system which is a big data-sharing platform to provide logic, efficiency, sustainability, and enhanced collaboration for the planning work schedules. It is shown that BIM or digital twin can help visualization and prioritization of the maintenance options and estimation of the associated costs. Wyman (2014) states that companies whose top priority is sustainability will gain massive advantage against their competitors.

This paper concerns the disadvantages of traditional systems compared to smart systems, shortcomings of the integration of advanced technologies into the railway tracks, and also achieving sustainability and gaining long-term benefits by using smart systems. The first two are discussed above. The last one will be the issue of this chapter. Usually, the long-term effects of a structure are evaluated by its life cycle. The life cycle is the examination of the entire process from the raw material state of a product to its production, use, maintenance, and recycling or removal from production. The life cycle cost (LCC) concept, throughout the life cycle of a system or product; is defined as the sum of the costs incurred for the development, production, operation, and removal of the system from the inventory (ORR, 2017).


In the railway, which is built with the aim of long-term use with high construction costs, the maintenance periods that will occur during use are very important for the life of the railway line. This has created the life cycle concept in terms of enabling us to make the system work

with a maximum performance by establishing the life cycle of all products in our system, from the smallest part to the largest part, and maintaining and changing them at the right times.

Railway use is an important point in the choice of transportation investment type of many developed and developing countries due to its being safe, sustainable, environmentally friendly, and efficient. In growing and producing societies, the need for railways for the fast, safe and economical transportation of products and people day is increasing. By the end of 2025, worldwide rail freight transport is expected to increase by approximately 14.75%, with 11912 tons of freight per kilometer. Likewise, it is expected that by 2025, passenger transportation by rail worldwide will increase by 37,2% compared to 2015 (Attoh-Okine, 2014).

In addition, although railway investments have been made in many countries, it has been observed that these investments cannot meet the increasing demands. For example, despite advanced rail investments in the UK, there was an increase of approximately 4,8% in human transport between 2010-2011 and 2016-2017, making the British railways the second busiest railway line in Europe (ORR, 2017). Similarly, over the same years, the number of people traveling by rail increased by 11%, although there was only a 4,8% increase in rail track length in the United States. Likewise, although the railway investments in India are only 4,5%, the number of passengers has increased by 6%. (APTA, 2017) With the increase in the number of people using the railway line, the density of the line will increase with the increase in the number of trips. With such increases, the line will deteriorate with the use of the line above its capacity and the maintenance costs of the line will increase. In order to keep the life cycle of railway lines built with high investment costs long and reliable, it is necessary to use the available resources in the best way. Especially in conventional ballasted railway lines, railway line maintenance directly affects the condition of the railway line, the possibility of accidents that may occur with the settlements or deformations, fuel rates of railway vehicles and wheel and rail maintenance costs, travel time costs, and emissions. Taking good care of the railway line affects driving safety and driving comfort. It also increases the lifetime of the line.

For these reasons, an effective asset management system that systematically takes into account all life cycle costs (WLCC) and the lifecycle benefits of the line is needed in order to get maximum efficiency from the railway line and to use the line safely (see Figure 5). This approach finds the causes of cost factors and allows the most cost-effective fixes to be found, as well as comparing alternative care options and finding where to use maintenance



resources first.

Figure 4. All Lifecycle Costs adapted from ISO 15686-5 (2017) (Sasidharan et al, 2020)

Maintenance periods for railway infrastructure in general use proceed according to pre-planned schedules according to time and road carrying capacity. However, with the increase in the use of railways, the railway may need maintenance and renovation works in earlier periods. However, when acting according to pre-planned maintenance times, maintenance cannot be carried out under optimum conditions. In the absence of maintenance and repair work under optimum conditions, maximum benefit cannot be obtained from the railway. This situation is

gradually changed towards intelligent maintenance and maintenance at the right time.

Railway line maintenance and renewal costs include direct costs to examine the condition of the railway line, to operate it, and to renew the places deemed necessary and indirect costs that require line maintenance such as delays, accidents, and emission situations. The useful life cost is the cost of the railway system at the end of its useful life.

In Figure 5, different cost variables that may occur in the life cycle of the railway line are given as a function for the average railway line construction and expenses (Marschnig, 2016). As can be seen from the given function graph, higher construction and maintenance costs are required to build a better quality and durable railway line. On the other hand, the higher the quality of the railway line, the longer the maintenance and renewal times of the line, so the costs will decrease. The figure shows the minimum total transport cost (TCS1) the ideal average rail condition (TQS1) or the optimum maintenance conditions. Line construction cost in ideal standards has been shown at MCS1 point. In the line construction condition (TQS2) lower than the ideal line condition, maintenance costs may decrease (MCS2), but it causes an increase in the usage and operating costs of the line (UCS2). An increase in rail line operating costs is more costly than maintenance under optimum conditions (TQS1), resulting in higher transport costs. In another way, building a better quality and larger rail line than ideal conditions (TQS3) causes an increase in maintenance costs but decreases usage costs.




Figure 5. Optimal railway track maintenance standard (Sasidharan et al. 2020)

Railway maintenance of the railway line until the line construction costs and manage operating costs is also very important. Because the construction costs of railway line investments are very high, therefore, the expected service life of the railway line can be

extended by managing the maintenance and operating costs under optimum conditions. As can be seen in Figure 7, the long-term effects of investments and measures made in the short term are shown.




Figure 6. Short-term savings and their long-term consequences (Veit 2007).

The life cycle cost of the railway line can be defined as the sum of maintenance, operation and renewal, and depreciation costs. When costs are analyzed in the life cycle of railway lines, economic analyzes are calculated over annual revenues, as the depreciation value is the main factor as the useful service life of the line (Veit, 2007). As the service life of the railway line increases, the number of depreciation decreases. Maintenance and replacement costs increase over time. As a result, optimum time can be found to renew or maintain the line, so that the railway line reaches its maximum service life with minimum costs.

In order to provide maximum service life with minimum cost in the life cycle cost of the railway line, the life cycle of all kinds of parts used in line construction should be analyzed and all analyzes should be brought together and the maintenance and operation system should be planned. Otherwise, the railway line may become unusable in its maximum service life, or maintenance costs may be higher than expected.

The technical service life of the railway line can be used longer than its calculated economic life. However, maintenance costs may become higher than calculated here, so the life cycle cost of the line increases. As a result, using the line beyond its technical service life will increase the life cycle cost, thus deviating from the optimum cost.

The life cycle cost of the railway line may increase or decrease due to the reasons described, as well as the deformations that may

occur in the railway line and in the infrastructure of the railway line with the increase in the usage density of the line. For this reason, the control engineers of the line have a very important task in taking sustainable measures and establishing follow-up periods.

There are three basic situations for short-term savings in asset management in the rail system. The first case is the reduction of maintenance work, the second case is the reduction of line renewal efforts, and the third is the reduction of both line maintenance and line renewal efforts.

Figure 6 defines the situation as the steady state, which shows that the line aspect and renewal costs of the railway line in the most basic case in the reference state of 0 are approximately the same for all lines and all units in the line. Looking at the 0-A situation, it is seen that short-term reductions in maintenance lead to a shortened service life of the parts of the railway line. In this way, they can be out of service before reaching their technical life. In this way, if maintenance periods are extended as not timely, parts may need to be replaced before they reach the end of their service life. This situation raises the life cycle costs to a higher level. When looking at the 0-B situation from Figure 6, the results of the savings made in the short term with regard to the renewal studies, which are more important, can be seen. If the demands for renewal in the railway line decrease, it may be that the parts on the line are subject to excessive deformation. This requires high maintenance costs to restore parts to their old quality. When we look at the 0-AB situation,

it means that both maintenance and replacement costs are cut at the same time and the other two situations come together. When we consider in the long term, life cycle and life cycle costs increase at the same time with both high maintenance costs and frequent renewal. This situation can be used at times when maximum benefit is desired by deviating from optimum conditions.

To summarize the comparison of the three scenarios with state 0, it ceases to be sustainable in state 0, although both maintenance and replacement costs are important for short-term savings. This situation brings with it a great cost of change in the railway line in the long run. Particularly in the 0-B situation and in the 0-AB case, parts will require replacement with new parts in the long run due to the early reach of their useful life, and in this case, there may be shutdowns or speed restrictions for a certain period of time due to the works in the infrastructure and superstructure.

In line with all these plans, the right interventions should be made at the right times by establishing a maintenance and renewal program in order to ensure the sustainable operation of the railway line under optimum conditions. The contents of this plan should answer some questions; "When will which part of the railway line be taken into maintenance?", "What are the service lives and remaining service lives of the materials used?" and "If the railway line needs to be renewed, what are the reasons?". Since railway structures consist of multi-factor components and all components affect each other, it may not be possible to find the optimum time by combining each value. However, the best program can be created with various approaches. For these reasons, the railway line should be analyzed in detail and the areas that need maintenance or replacement should be determined first. The causes of malfunctions that may occur afterward should be determined and measures should be taken accordingly. After these evaluations, it should be decided that ongoing maintenance or renovation works are economical and sustainable. In order to use the available financial resources efficiently, additional costs that may occur in case of postponement of possible maintenance or renewal works should be calculated. If all these are done with the order and analysis shown in Figure 7, the efficient use

of the budget will ensure maximum efficiency from the railway line.

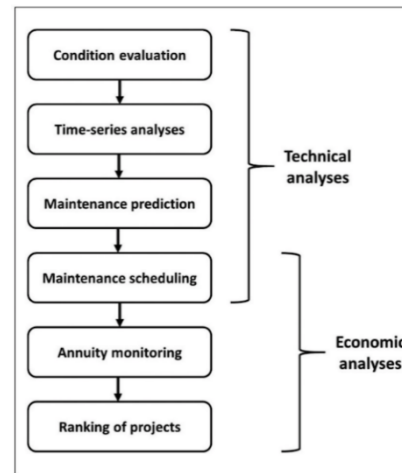


Figure 7 Life cycle process of assets (Neuhold et al, 2020)

In summary, by preparing a suitable life cycle management for the railway line and applying this management at the right time and conditions, maximum benefit is achieved with optimum maintenance and renewal costs. In the part of managing the railway line throughout its life cycle, the main purpose is to perform the line renewal when necessary by keeping the quality of the line at optimum levels with effective maintenance techniques. The time of maintenance techniques and how they will be done can be determined with the help of smart systems and appropriate maintenance or replacement where necessary.

All these findings reveal the importance of smart diagnosis and maintenance methods in life cycle analysis. The first step of life cycle analysis is condition evaluation, and this step is achieved more effectively with smart systems. Because in the innovative system, more frequent data collection has been suggested, so that training can be carried out on larger data sets. By using ML techniques, predictions are made for future failure base on historical data.

Using smart methods enables us to locate the steps we take in the life cycle accurately and on time. If we do the right maintenance and repairs in the right places at the right time, we will run our system in the most optimum condition. This provides an economy throughout its life cycle and makes it more sustainable.

7. Conclusion

This paper investigated the application of smart diagnosis and maintenance systems to the railway tracks in order to increase the performance of failure prediction, establish an optimal maintenance plan, and extend the structure's service life. Comparison of the traditional way with the smart way of track maintenance highlights a significant difference between their technique for the determination of the threshold that is used as the evaluation criteria for maintenance. In traditional maintenance, the threshold is set by the standards. Maintenance decisions are made through the comparison of track geometry data collected from measurement vehicles with the threshold value. Smart maintenance systems, on the other hand, may detect the deterioration rate of the track. In addition to measurement trains, measurement systems can be implemented to various types of track and more frequent data collection can be achieved. In other words, preventive maintenance based on real-time data takes place instead of uniform rules based on past data. The size and quality of the data provide better failure prediction models for ML and a more proper maintenance plan.

A literature review of the existing smart diagnosis and maintenance applications shows that advanced technologies are not fully integrated into the railway tracks so far and there are some challenges to overcome for better performance. AI is used not only for prediction models but also for decision-making assistance. In order to develop AI experts that can interpret the situation, more improved NLP techniques must be used. The large volume of data produced by sensors requires proper storage, management, and operation which can be a challenge for the companies. Image processing can also be challenging in railway track use because of the existence of oil and dust that lower the quality of the images. Publicly available labeled datasets can increase the performance of the ML models. However, most of the rail data are not publicly available and not labeled. Therefore, sharing datasets or supporting professionals will increase the performance. Also, auto-labeling systems must be developed. Recent studies show that one of the most important drawbacks of the integration of IoT to the railway system is its high price. Inspection of railway tracks require sensors with various functionalities whose

instrumentation can be costly. Thus, further research and development must be done about IoT devices to reduce the costs. Besides, technology companies must build the understanding that intelligence and sustainability of the systems are connected to each other. Therefore, sustainability must be one of the priorities of these companies to enhance the efficiency of their products.

Once these challenges are overcome, railway tracks may be an integrated part of the future's smart and sustainable cities. Railways can be evaluated as high initial cost investments but they provide long-term benefits. The use of smart systems allows engineers to create an optimum maintenance plan and the proper plan contributes to the extension of the life cycle of the track, making it not only smart but also sustainable.

Acknowledgement and/or disclaimers

There is no support for this work.

Conflict of Interest

No conflict of interest was declared by the authors.

References

- Al Nuaimi, E., Al Neyadi, H., Nader, M., Al-Jaroodi, J.** (2015). Applications of big data to smart cities. *Journal of Internet Services and Applications*, vol. 6, no. 25, 1–15.
- Andre, L. O. De Melo, Kaewunruen S., Papaalias M., Liedt L.B. Bernucci, Motta R.** (2020). Methods to Monitor and Evaluate the Deterioration of Track and Its Components in a Railway In-Service: A Systemic Review. *Frontiers in Built Environment*, 6, Article 118.
- APTA.** (2017). *Ridership report – quarterly and annual totals by mode*. Retrieved January 12, 2021 from www.apta.com/resources/statistics/Pages/ridershipreport.aspx.
- AREMA (American Railway Engineering and Maintenance-of-Way Association).** (2016). *Manual for railway engineering*, Vol. 4, Lanham, MD.
- Asplund, M.** 2016. *Wayside condition monitoring technologies for railway systems*. PhD thesis. Sweden: Lulea University.

Attoh-Okine, N. (2014). Big data challenges in railway engineering. *In 2014 IEEE International Conference on Big Data.*

Baker, T., Al-Dawsari, B., Tawfik, H., Reid, D., Ngoko, Y. (2015). GreeDi: An energy efficient routing algorithm for big data on cloud. *Ad Hoc Netw.*, vol. 35, 83–96.

Baker, T., Ngoko, Y., Tolosana-Calasanz, R., Rana, O. F., Randles, M. (2013). Energy Efficient Cloud Computing Environment via Autonomic Meta-Director Framework. *Proc. IEEE Int. Conf. Develop. eSyst. Eng. (DeSE)*, Abu Dhabi, UAE, 198–203.

Balci, E. (2019). Overview of Intelligent Personal Assistants, *Acta Infologica*, 3(1), 22-33.

Bibri, S. E. (2015). The human face of Ambient Intelligence. *Cognitive, Emotional, Affective, Behavioral, and Conversational Aspects*, Springer-Verlag, Berlin, Heidelberg.

Bibri, S. E., Krogstie, J. (2016). On the social shaping dimensions of smart sustainable cities: A study in science, technology, and society. *Sustainable Cities and Society*, vol. 29, 219–246.

Bibri S. E., Krogstie, J. (2017b). ICT of the new wave of computing for sustainable urban forms: Their big data and context-aware augmented typologies and design concepts. *Sustainable Cities and Society*, vol. 32, 449–474.

Bibri S. E., Krogstie, J. (2017c). The core enabling technologies of big data analytics and context-aware computing for smart sustainable cities: A Review and synthesis. *Journal of big Big Data*, vol. 4, no. 38, 1–50.

Bibri, S. E., Krogstie, J. (2017a). Smart sustainable cities of the future: an extensive interdisciplinary literature review. *Sustainable Cities and Society*, vol. 31, 183–212.

Castillo-Mingorance, J.M., Sol-Sánchez, M., Moreno-Navarro, F., Rubio-Gámez, M.C. (2020). A Critical Review of Sensors for the Continuous Monitoring of Smart and Sustainable Railway Infrastructures. *Sustainability*. 12(22):9428.

Edwards, J. R., Mechitov, K. A., Barbosa, I.G., de O Lima, A., Spencer, B. F., Tutumluer, E., Dersch, M. S. (2021). A Roadmap for Sustainable Smart Track—

Wireless Continuous Monitoring of Railway Track Condition. *Sustainability*, 13(13), 7456.

EN 13848-5:2008+A1:2010 railway applications – track – track geometry quality. (2008). – Part 5: geometric quality levels-Plain line

Faghih-Roohi, S., Hajizadeh, S., Nunez, A., Babuska, R., De Schutter, B. (2016). Deep convolutional neural networks for detection of rail surface defects. *In Proceedings of International Joint Conference on Neural Networks*, 2584-2589.

Hayashi, Y., Kojima, T., Tsunashima, H., Marumo, Y. (2006). Real time fault detection of railway vehicle and tracks. *In International conference on railway condition monitoring*, Birmingham, UK, 20-25.

Jamshidi, A., Faghih-Roohi, S., Hajizadeh, S., Núñez, A., Babuska, R., Dollevoet, R., Li, Z., De Schutter, B. (2017). A Big Data Analysis Approach for Rail Failure Risk Assessment. *Risk Analysis*, 37, 1495-1507.

Jamshidi, A., Hajizadeh, S., Su, Z., Naeimi, M., Núñez, A., Dollevoet, R., Schutter, B. De, Li, Z. (2018). A decision support approach for condition-based maintenance of rails based on big data analysis. *Transportation Research Part C: Emerging Technologies*, 95, 185-206.

Jo, O., Kim Y., Kim J. (2018). Internet of Things for Smart Railway: Feasibility and Applications. *IEEE Internet of Things Journal*, vol. 5, no. 2, 482-490.

Johansson, N., Roth, E., Reim, W. (2019). Smart and Sustainable eMaintenance: Capabilities for Digitalization of Maintenance. *Sustainability*, 11(13), 3553.

Kaewunruen, S., Lian, Q. (2019). Digital Twin aided Sustainability-based Lifecycle Management for Railway Turnout Systems. *Journal of Cleaner Production*.

Kelly, S. D. T., Suryadevara, N. K., Mukhopadhyay, S. C. (2013). Towards the implementation of IoT for environmental condition monitoring in homes. *IEEE Sensors J.*, vol. 13, no. 10, 3846–3853.

Kugurakova, V., Talanov, M., Manakhov, N., Ivanov, D. (2015). Anthropomorphic Artificial Social Agent with Simulated Emotions and its Implementation. *Procedia Computer Science*, 71, 112-118.

- Kuila, P., P. Jana, P.K.** (2014). Energy efficient clustering and routing algorithms for wireless sensor networks: Particle swarm optimization approach. *Eng. Appl. Artif. Intell.*, vol. 33, 127–140.
- Li, C., Luo, S., Cole, C., Spiriyagin, M.** (2017). An overview: modern techniques for railway vehicle on-board health monitoring systems. *Vehicle System Dynamics*, 55(7), 1045-1070.
- Marschnig, S.** (2016). Innovative track access charges. *Transportation Research Procedia*, 14, 1884-1893.
- Martinez, B., Montón, M., Prades, J. D.** (2015). The power of models: Modeling power consumption for IoT devices. *IEEE Sensors J.*, vol. 15, no. 15, 5777–5789.
- Mohanty, S. P., Choppali, U., Kougianos, E.** (2016). Everything you wanted to know about smart cities: The Internet of things is the backbone. *IEEE Consumer Electronics Magazine*, 5(3), 60-70.
- Nakhaee M. C., Hiemstra D., Stoelinga M., Noort M.V.** (2019). The Recent Applications of Machine Learning in Rail Track Maintenance: A Survey. *Springer Nature Switzerland, RRSRail.*, 91-105.
- Neuhold, J., Landgraf, M., Marschnig, S., Veit, P.** (2020). Measurement Data-Driven Life-Cycle Management of Railway Track. *Transportation Research Record*, 2674(11), 685-696.
- ORR.** (2017). Network rail monitor – quarters 3-4 of year 3 of CP5 16-17 (London)
- Peng, F.** (2011). Scheduling of track inspection and maintenance activities in railroad networks. PhD Dissertation, University of Illinois at Urbana-Champaign
- Santur, Y., Karaköse, M., Akın, E.** (2016). Condition Monitoring Approach Using 3D-Modelling of Railway Tracks with Laser Cameras. *In International Conference on Advanced Technology & Sciences (ICAT'16)*, 132-135.
- Sasidharan, M., Burrow, M. P. N., Ghataora, G. S.** (2020). A whole life cycle approach under uncertainty for economically justifiable ballasted railway track maintenance. *Research in Transportation Economics*, 100815.
- Snijders, C., Matzat, U., Reips, U.-D.** (2012). Big data: Big gaps of knowledge in the field of internet science. *International Journal of Internet Science*, 7(1), 1-5.
- Song, B. Y., Zhong, Y., Liu, R. K., Wang, F. T.** (2014). Railway Maintenance Analysis Based on Big Data and Condition Classification. *Advanced Materials Research*, 919-921, 1134-1138.
- Tan, L., Wang, N.** (2010). Future internet: The Internet of Things. *In 3rd International Conference on Advanced Computer Theory and Engineering (ICACTE)*, 5., 376-380.
- Tokody D., Schuster, G., Papp J.** (2015). Study of how to implement an intelligent railway system in Hungary. *IEEE 13th International Symposium on Intelligent Systems and Informatics (SISY)*, 199-204.
- Van Noortwijk, J. M.** (2004). Gamma process model for time-dependent structural reliability analysis. *In Numerical Modelling of Discrete Materials in Geotechnical Engineering, Civil Engineering and Earth Sciences: Proceedings of the First International UDEC/3DEC Symposium*, Bochum, Germany, 29 September-1 October 2004 (p. 101). CRC Press.
- Veit, P.** (2007). Track Quality—Luxury or Necessity?. *Railway Technical Review—RTR Special*, 8-12.
- Wyman O.** (2014). From Green to Sustainable: Developing a Holistic Approach to Sustainable Business Growth. *Marsh and McLennan Companies. Oliver Wyman's Sustainable Center.*
- Yokoyama, A.** (2015). Innovative changes for maintenance of railway by using ICT -To Achieve “Smart Maintenance”. *Procedia CIRP*, 24-29.
- Zoeteman, A., Dollevoet, R., Li, Z.** (2014). Dutch research results on wheel/rail interface management: 2001-2013 and beyond. *Proceedings of the Institution of Mechanical Engineers Part F: Journal of Rail and Rapid Transit*, 228, 642-651

Review Article

Different application areas of object detection with deep learning

Sevcan Turan^{1,*}, Bahar Milani², Feyzullah Temurtaş³

¹ Çan Vocational School, Çanakkale Onsekiz Mart University, Çan, Turkey

² Department of Computer Engineering, Faculty of Engineering and Natural Sciences, Bandırma Onyedi Eylül University, Bandırma, Turkey

³ Department of Electrical and Electronic Engineering, Faculty of Engineering and Natural Sciences, Bandırma Onyedi Eylül University, Bandırma, Turkey

*Correspondence: sevcanturan@comu.edu.tr

DOI: 10.51513/jitsa.957371

Abstract: Automation is spread in all daily life and business activities to facilitate human life and working conditions. Robots, automated cars, unmanned vehicles, robot arms, automated factories etc. are getting place in our lives. For these automated actors, one important task is recognizing objects and obstacles in the target environment. Object detection, determining the objects and their location in the environment, is one of the most important solution for this task. With deep learning techniques like Convolutional Neural Network and GPU processing, object detection has become more accurate and faster, and getting attention of researchers. In recent years, many articles about object detection algorithms and usage of object detection have been published. There are surveys about the object detection algorithms, but they have introduced algorithms and focused on common application areas. With this survey, we aim to show that object detection algorithms have very large and different application area. In this study, we have given a brief introduction to deep learning. We have then focused on standard object detection algorithms based on deep learning and their applications in different research areas in recent years to give an idea for future works. Also, the datasets and evaluation metrics used in the research are listed.

Key Words: Object detection, deep learning, CNN, LSTM

Derin öğrenme tabanlı nesne algılama işlemlerinin farklı uygulama alanları

Özet: Otomasyon, insan yaşamını ve çalışma koşullarını kolaylaştırmak için günlük yaşamda ve iş hayatında yaygınlaşmaktadır. Robotlar, sürücüsüz arabalar, insansız araçlar, robot kollar, otomatik fabrikalar vs. hayatımıza hızla girmektedir. Bu otomatikleştirilmiş aktörler için önemli görevlerden biri, çalışılacak ortamdaki nesnelere ve engelleri tanımadır. Nesne algılama -nesnelere cinsinin ve ortamdaki konumlarının belirlenmesi- bu görev için en önemli çözümlerden biridir. Evrişimli Sinir Ağı ve GPU işleme gibi derin öğrenme teknikleri ile nesne algılama işlemleri daha doğru ve hızlı sonuç üretmeye başlamış ve araştırmacıların dikkatini çekmiştir. Son yıllarda nesne algılama algoritmaları ve nesne algılamanın kullanımı ile ilgili birçok makale yayınlanmıştır. Nesne algılama algoritmaları hakkında inceleme makaleleri de bulunmaktadır, ancak genel itibarıyla algoritmaları tanıtmış ve çok yaygın olarak bilinen uygulama alanlarına odaklanmışlardır. Diğer inceleme makalelerinden farklı olarak, bu çalışmada nesne algılama algoritmalarının çok geniş ve farklı uygulama alanına sahip olduğu gösterilmek istenmektedir. Çalışmada, derin öğrenmeye kısa bir giriş yapıldıktan sonra derin öğrenmeye dayalı standart nesne algılama algoritmaları ve bunların son yıllarda farklı araştırma alanlarındaki uygulamalarına yer verilerek gelecekteki çalışmalar için rehber olmak amaçlanmaktadır. Ayrıca makalelerde kullanılan veri setleri ve değerlendirme ölçütleri de listelenmiştir.

Anahtar Kelimeler: Nesne algılama, derin öğrenme, CNN, LSTM

* Corresponding author. Tel.: 0 286 416 77 05

ORCID: 0000-0003-4278-7406, 0000-0002-5295-4215, 0000-0002-3158-4032

Received 27 June 2021; accepted 31 August 2021

Peer review under responsibility of Bandırma Onyedi Eylül University.

1. Introduction

Object detection is fundamental to defining an object's type and location in an image or video frame. Studies about object detection can be categorized into two domains, detection of known objects and detection an object that belongs to a category. For a few years, the object detection accuracy was limited due to restriction of computation cost, machine learning algorithms, and sample datasets size (Krizhevsky et al., 2017). With innovations in deep learning, GPU processing, large datasets the object detection in a category has become the most attractive topic (L. Liu et al., 2020).

In 2012, at ImageNet Large Scale Visual Recognition Challenge (ILSVRC), there has been a giant leap in object category detection with deep learning (Russakovsky et al., 2015). In this challenge, Krizhevsky et al. (2017) presented AlexNet, a Deep Convolutional Neural Network (DCNN). They have changed the direction of studies, so deep learning has become an essential tool for object detection. The innovation in object detection is used in health, robotics, transportation, security, manufacturing, scientific research about sky and earth, etc. (L. Liu et al., 2020).

In some of the surveys structure, metrics, performance etc. of object detection algorithms have been examined and compared, and then some common application areas have been given as examples (Jiao et al., 2019; L. Liu et al., 2020; Padilla et al., 2020; Zou et al., 2019). Also, some of the surveys have been focused on specific application area, for example salient objects (Borji et al., 2019; J. Han et al., 2018; W. Wang et al., 2021), traffic objects (Arnold et al., 2019; Sanyal et al., 2020), remote sensing objects (Cheng & Han, 2016; K. Li et al., 2020), objects that recognized by unmanned aerial vehicle (Cazzato et al., 2020; Mittal et al., 2020), etc. There is not a survey focused on showing how wide the usage area of the object detection. This study's contribution is presenting different application area of object detection based on deep learning with dataset and evaluation metrics they have used. The studies are selected from the separate topic for projecting the usage area of object detection to motivate the next studies.

In this study, in the second part most used deep learning architecture is introduced. Then, in the third part, common object detection algorithms

and object detection research are examined. In the fourth part the discussions and in the last part the conclusions are presented.

2. Deep Learning Architecture

Deep learning, a branch of machine learning, is a technique for predicting the system's expected results from the various number of sample data without human interaction (LeCun et al., 2015). Its structure is based on an artificial neural network with a multi-hidden layer. As seen in Fig. 1, there are three main layers: input, hidden, and output. The input layer is used for collecting the input data, and the hidden layer is used for extracting features from the data and, the output layer is used to predict the results. Each layer consists of neurons, and in neurons, the inputs x_i are multiplied with the weights w_i , and the results are summed. The produced results are passed as input to the next layer (Öztemel, 2012).

Deep learning consists of two primary processes, as shown in Fig.1: a) Forward computing for predicting results from the input and b) Backpropagation for updating the weights to reduce the prediction error.

There are three main types of learning strategy for training deep neural network (*Ufddl Tutorial*, n.d.):

- Supervised Learning: Data and its labels determined by an expert of the domain are used to train the network. The predicted result is compared to the tags. And due to the difference between them, the weight of the neurons is updated.
- Semi-Supervised Learning: Data with and without labels used for training. There are more unlabelled data and a few labelled data available.
- Unsupervised Learning: Data without labels are used for training, and the system clusters the input according to similarities to each other.

2.1. Convolutional neural network (CNN)

CNN is the most used architecture for the object detection process introduced by LeCun et al. (1989). CNN is used for image classification (Cevikalp et al., 2020), image segmentation (Turan & Bilgin, 2019), speech recognition (Pavan et al., 2020), object detection (R

Girshick et al., 2016; Ross Girshick, 2015; Krizhevsky et al., 2017; Law & Deng, 2018; Redmon et al., 2016; Ren et al., 2017), object

tracking (Yuan et al., 2020), network management (Vinayakumar et al., 2017), etc. In Fig. 2, the architecture of CNN is shown.




Figure 1. Deep learning architecture. a) Computation the forward pass. b) Backpropagation for learning (LeCun et al., 2015)

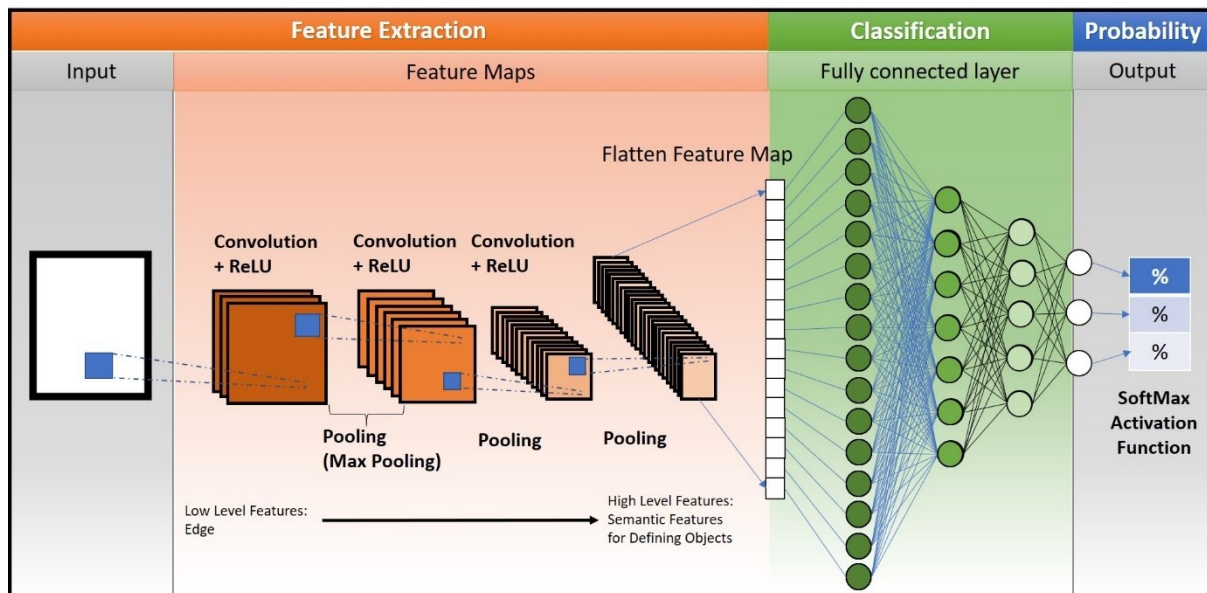


Figure 2. Architecture of CNN

The main part of the architecture is as follows (Indolia et al., 2018):

- Convolution Layer**
In the convolution layer, the input is convolved with filters, and this is done several times. In the early convolution steps, the basic features are obtained as edge, and in the last stages, the features represent the object is obtained.
- Pooling**
In pooling, the feature map size is reduced to get the most relevant feature

representing the target objects. For this process, a 2x2 grid is taken from feature map, and in general with maximum pooling (MaxPooling) algorithm the new feature value for the next step is calculated. In the MaxPooling algorithm, the maximum value in grid is taken.

- Activation Function**
For providing nonlinearity, an activation function is used. In a neuron, the input goes to the activation function. Then the result is sent to the

next layer of the network. The most used function is Rectified Linear Unit function (ReLU). In ReLU, negative values are converted to 0, and the positive values stay the same.

- d. Fully Connected Layer and Classifier
The fully connected layer is the classic neural network layer whose nodes are fully connected to the previous layer used to calculate the object class score. In this layer, first, the feature map is flattened, and a feature vector is

obtained for using as the input of the classic neural network system. The result of the network is classified with function like SoftMax.

2.2. Recurrent neural network (RNN)

RNN is the network that can be used for learning from sequence data introduced by Elman (1990). As shown in Fig. 3 at time t , x_t and h_{t-1} which is previous hidden state value are the inputs, and o_t is the output, and h_t is the new hidden state of the network.




Figure 3. Architecture of RNN (Many inputs, many outputs)

For each time step, same w_x , w_y and w_h are used respectively as input, output, and hidden state weights. The hidden state of the network h_{t-1} where $i=1,2,3, \dots, t$, is used as input for each next time step. In this way, RNN can use the historical data for prediction. But, according to vanishing gradient problem, RNN cannot be used for recalling long time history.

(Bahdanau et al., 2016), video processing (W. Zhang et al., 2016), etc.

RNN is used for natural language process (Lawrence et al., 2000), speech recognition

2.3. Long short-term memory (LSTM)

LSTM, a type of RNN, is used for keeping information for a long duration which was developed by Hochreiter and Schmidhuber (1997). In LSTM, memory cells contain input gate, forget gate, cell state, output gate, input activation function, and output activation function (Gers et al., 1999), as shown in Fig. 4.

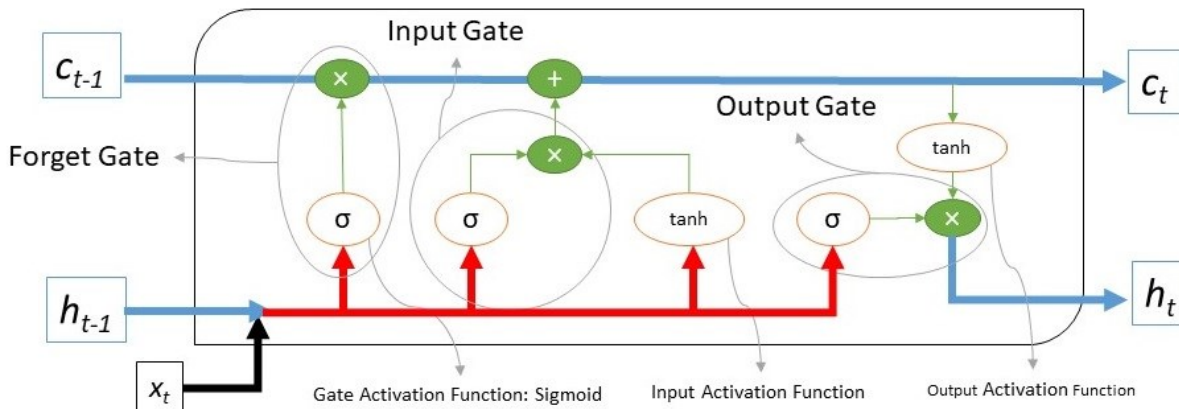


Figure 4. Architecture of LSTM memory cell

Cell state is used for transferring long-term historical information in the network. Forget gate is used to decide which values from the input and previous output of the network will affect the cell state. Input gate is used for deciding which input values will affect the cell state. Output gate is used for generating network result with cell state. At time t , input x_t , the previous output of network h_{t-1} and cell state c_{t-1} are given as input parameters to network, and output h_t and new cell state c_t are produced. At forget gate, h_{t-1} and x_t are feed to the activation function, and the result of the gate is bitwise multiplied with the c_{t-1} for deciding which values will be forgotten. At the input gate, h_{t-1} and x_t is fed to the activation function to determine which input values will affect the cell state, and the result of the gate is multiplied with the result of input activation function. And the resultant value is summed with cell state c_{t-1} and produced the new cell state c_t . At the output gate, h_{t-1} and x_t are feed to the gate activation function, and the c_t is fed to the output activation function, and the results are multiplied, and h_t is produced. h_t and c_t are passed to $t+1$ process.

LSTM is used for object detection in video (Sorano et al., 2020), object tracking (Tsai et al., 2020), speech recognition (J. Li et al., 2020), video processing (Xiao et al., 2020), natural language process (Jelodar et al., 2020), etc.

3. Works on object detection

In this section, the most common object detection algorithms and their applications in other research area are examined. The studies which use object detection have been selected from the recent years for limiting the paper content.

As seen from the studies in Table 1, most object detection algorithms based on CNN can be used to get the features of objects. CNN-based algorithms handle the inputs as independent from each other. It takes an image, detects the objects, passes to the new one, and the relationship between the scenes is not considered. RNN/LSTM is used if the input is handled as a sequence. Some researchers divide input into regions and consider regions as time series (W. Han et al., 2020; Kechaou et al., 2020).

AlexNet is the turning point of the studies. They used 15 million labelled RGB images with

256×256 resolution from the ImageNet dataset, five convolution layers, and three fully connected layers for training a CNN network for image classification. They used the ReLu activation function, 2×2 pooling grid size, and dropout layer. They used GPU for computation convolutions. As a result, they achieved a 15.3% error rate and gained significant success. This classification technique has been used as a backbone network for object detection, and it has been a guiding idea for researchers.

In object detection, there are two leading groups of CNN-based algorithms: One-stage and two-stage algorithms. One-stage algorithms are fast, but two-stage algorithms are more accurate. So, the researcher should decide whether the speed or accuracy is essential for this issue. Some of the common CNN based object detection algorithms are as follows:

- R-CNN, Fast R-CNN, Faster R-CNN: Region-Based Convolutional Neural Network (R-CNN) is a two-stage algorithm. At the first stage, 2000 proposal regions are found by a Selective Search Algorithm (SSA) from the image that are candidates for containing objects. Then these proposals are sent to the neural network, and a feature map is produced. Then object class and bounding box is getting from feature map. The objects are detected with 53.3% mean average precision (mAP) on Pascal VOC 2012 (*Pascalvoc*, n.d.) dataset (Girshick et al., 2014). In 2016 this team introduced a new version of R-CNN with 62.4% mAP (R Girshick et al., 2016). The R-CNN algorithm is so slow because of SSA and running network for 2000 times, therefore Fast R-CNN has been introduced to develop accuracy and computation performance (Ross Girshick, 2015). In the Fast R-CNN training process, images and object proposals are used as input and a feature map is produced. The features are selected for object detection in the Region of Interest Pooling algorithm by using object proposals and feature maps. After a fully connected layer, with Softmax classifier object categories, and with Bounding Box Regression bounding boxes are found. Objects are detected with 68.4% mAP

and 9.5-hour training time, 0.32 second testing time on Pascal VOC 2012+2007 dataset. R-CNN and Fast R-CNN are used SSA to find regions and are slow for real-time object detection. New algorithm Faster R-CNN has replaced this selection algorithm with Region Proposal Network (Ren et al., 2017). In Faster R-CNN, the image is feed to convolution layers, and a feature map is produced. Using feature maps, region proposals are learned with Region Proposal Network. Objects are detected, using Softmax classifier and bounding box regression, with 75.9% mAP on Pascal VOC 2007+2012 and MS COCO (Mscoco, n.d.) dataset combination.

- YOLO (Redmon et al., 2016): YOLO is a one-stage algorithm. In this study, the image is divided into grids with dimensions 7×7 . And each grid is responsible for detecting even if there is an object in it. If an object's centre is found in the grid, the grid is assigned to find the class category and two bounding boxes with the object's confidence score. Then the highest confidence score is selected for the category and bounding box. They have detected objects with 63.4% mAP on PASCAL VOC 2007+2012 dataset at real-time.
- SSD (W. Liu et al., 2016): In this study, VGG16 (Simonyan & Zisserman, 2015) has been used with some modification as the backbone to get a feature map. After VGG16, they have added six convolution layers, and classification and bounding box regression are done at different feature map scale, and for each class, 8732 predictions are found. Then the highest prediction rate is selected for determining objects. They have used six default boxes with different scales and orientations at different feature map sizes. If the boxes contain information about a class, then comparing ground truth, the offsets are determined, otherwise they are considered as background. Using different feature map sizes for prediction, they can detect the objects with varying sizes on the image. They have detected objects on 300×300 images with 74.3% mAP and 59 frames per second (fps), and 512×512 images with 76.9% mAP on the PASCAL VOC2007 dataset.
- RetinaNet (T. Lin et al., 2017): It is a one-stage detector that has achieved almost two-stage detectors. In this study, they have presented a new loss function named focal loss which eliminates the background values. They have used hard positive examples in training. In the algorithm of RetinaNet, Resnet (He et al., 2016) and Feature Pyramid Network (FPN) (T. Y. Lin et al., 2017) has been used as the backbone to get multi-scale feature maps, and an anchor box has been used for detecting object positions. For each FPN level, class and bounding box prediction networks are run separately. In this algorithm objects are detected with 39.1% average precision (AP) and 122 milliseconds on 600×600 -pixel images from the MS COCO dataset, more accurately than the two-stage algorithms.
- CornerNet (Law & Deng, 2018): It is a one stage detector which eliminates the anchor boxes, and object's coordinate is represented with two corner point, left-top and right-bottom, and a bounding box is drawn around the object with these points. For getting feature maps from the image, the Hourglass network is used as a backbone network. From the feature map, with a new corner pooling algorithm, they have found candidates of the left-top and right-bottom corner points as heatmaps, embeddings, and offsets. The distance between the embeddings is used to find the left-top and right-bottom points that belong to the same object. Then, they draw the bounding boxes. With 42.1% AP, they have detected the objects on the MS CO-CO dataset.
- CenterNet (Duan et al., 2019): It is a one-stage detector developed based on CornerNet. They have cascaded the corner pooling algorithm and added the centre point pooling mechanism. If the centre point of the bounding box has the feature representation about a class, this bounding box is chosen. In this way,

they have reduced the incorrect bounding box detection. They have achieved the highest accuracy than the other one-stage detector with 47.0% AP on the MS COCO dataset.

algorithms like above as well as develop new algorithms themselves. Some examples of the studies in the recent years at different research areas that use object detection are shown in Table 1.

According to research area and dataset properties, researchers can use ready-made

Table 1. *Samples of research used object detection in recent years.*

Ref. No	Dataset	Evaluation Metric	Research Detail With Contributions and Limitations
(Sardoğan et al., 2020)	Own dataset	<i>Diseased:</i> Accuracy: 0.84 Precision:0.92 Recall:0.80 F1-Score: 0.86 <i>Healthy:</i> Accuracy: 0.85 Precision:0.88 Recall:0.77 F1-Score: 0.82	They have used Faster R-CNN to detect the diseased and healthy leaves of apple tree from images which consists of many leaves. Their contribution is that the other studies generally have worked on images with one leaf, but their images contain many leaves. They have taken photos of trees leaves from different apple orchards in Yalova, Turkey for two years. They have annotated the images manually and showed the diseased and healthy leaves on the image. Their limitations are that the dataset needs to validation and accuracy must be improved.
(Chen et al., 2021)	Images collected by Taiwan Agricultural Research Institute, Council of Agriculture	F1-Score Mealybugs: 100% Coccidae: 89% Diaspididae: 97%	They have tried to detect three types of pests on the agricultural products before harming the product. They have focused on Mealybugs, Coccidae and Diaspididae which are the most seen pest in Taiwan. They have tested and compared the results of YOLOv4, SSD and Faster R-CNN, and found that YOLOv4 has provided the best results. They have also developed a mobile application based on cloud computation for farmers to detect pest on real time. Their contribution is that detection of different scale pests. Their limitation is that images in dataset contain only one type of pest, so the dataset is biased.
(Tassinari et al., 2021)	210-minute video captured in experimental farm at University of Bologna.	mAP: 0.64 - 0.66	They have detected dairy cows and collected information about them for sustainability of the highly utilized farming. They have used YOLOv3 to detect the target cows. They have selected four cows and they have gotten video contains these cows' daily activities. They have annotated the video for training process. As contribution, they can differentiate the individual cow using its color pattern, detect and track at video frame and store information about it. As limitation, they labeled each cow with two types of class separately according to left and right-side posture, but front and back postures were not considered. Each cow was represented with two class and when the number of cows increase the number of classes will increase with double.

(Hacıfendioğlu et al., 2021)	Images acquired by Google Earth Pro software after Palu earthquake in 2018.	Ground Failure area: 0.684 AP Buildings: 0.432 AP	They have used Faster R-CNN for detecting the ground failures and damaged buildings after the earthquake in Palu / Indonesia in 2018 from satellite images. They have mentioned that the ground failures are the most damaging reason, and they have tried to find these areas to assess the damages. Sometimes, it cannot reach the area according to collapsed buildings or the environment's structure, so object detection determines the ground failure area and damaged buildings quickly to intervene. As contribution, they detected target objects from satellite images with deep learning techniques unlike the others only compare the images before and after earthquake. As limitation, the accuracy must be improved, and they have detected failure area and damaged structure with two separate system.
(Fan et al., 2020)	COD10K (10000 images 78 object categories The researchers have generated data set), CHAMELEON (Skurowski et al., 2017) and CAMO (Le et al., 2019)	Train with CAMO, COD10K and extra, test with Chameleon, E-measure: 0.891 S-measure: 0.869 F-measure (FM): 0.74 MAE: 0.044	They have detected the objects which camouflaged in a natural environment with a new algorithm based on CNN. ResNet-50 has been used as a backbone network for getting feature maps, and with additional convolutions, down and upsampling procedures they have detected the camouflaged objects. As contribution, they have developed new algorithm and dataset, and they tested their algorithm with their own dataset and another public dataset. As limitation, accuracy can be improved and images containing more than one object can be used.
(Pi et al., 2020)	Volan2018 (65,580 annotated frame from YouTube) (Pi et al., 2020)	80.69% mAP videos from helicopter footage 74.48% mAP for videos from drone.	They have used aerial imagery for detecting damaged areas after a disaster. They have detected six classes: the flooded area, building roofs (damaged/undamaged), cars, debris, vegetation. They have used YOLOv2 as an object detection algorithm. First, they have pre-trained YOLO on COCO and VOC, and then with transfer learning, they have trained the system with the Volan2018 dataset. As contribution, they have detected targets from aerial image of different hurricanes and geographical areas getting with drone and helicopter and they have created new dataset. As limitation when the altitude changes the accuracy decreases.
(Deng et al., 2020)	KITTI (Geiger et al., 2012) and WayMo Open Dataset (Sun et al., 2020)	81.62% AP on KITTI 75.59% mAP on Waymo	They have developed a 3D object detection algorithm from point cloud represented as voxel for autonomous cars. They have used a 3D backbone network to get feature maps and converted them to Birds Eye View. Then with the Volvex RoI Pooling algorithm, they have found the region proposals. With a 2D backbone network, they have detected the

			cars. As contribution, they have developed new algorithm based on point cloud and test it on public dataset. As limitation, accuracy can be improved.
(Liu et al., 2020)	ECSSD (Yan et al., 2013)	<i>ECSSD</i> : FM: 0.934 MAE:0.044	They have introduced an algorithm which consists of four main process part to detect a salient object. In the first part, there is a VGG16 backbone network. It is used for extracting shallow and deep features from the image at a different level. And the second part, each level of features is upsampled and utilized for getting enhanced feature maps. Results are sent to the third part for getting distinguishing features with upsampling operations. The last part of the algorithm generates the saliency map by using feature maps from deep to shallow, and finally determines the salient object. As contribution, they have developed new algorithm and tested it on public dataset and gotten higher accuracy than the compared studies. As limitation, on different dataset the accuracy and error rate are not stable, training process may be changed.
	DUT-OMRON (Yang et al., 2013)	<i>DUT-OMRON</i> : FM:0.809 MAE:0.055	
	PASCAL-S (Y. Li et al., 2014)	<i>PASCAL-S</i> : FM:0.880 MAE:0.071	
	HKU-IS (G. Li & Yu, 2016)	<i>HKU-IS</i> : FM:0.927 MAE:0.035	
	DUTS (Wang et al., 2017)	<i>DUTS</i> : FM:0.870 MAE:0.043	
(Lee, 2020)	Drone pictures and videos from search engine, and labeled manually by them	The highest value of AP on third strategy 0.736 with one pass evaluation.	They have presented object detection and tracking algorithms on video with three types of combination strategies on detection and tracking. They have used Tiny YOLO v3 as an object detector and SiamRPN as a visual tracker. In the first strategy, they have focused on tracking using the object's previous position, and if the tracker cannot find the object, the object detector is assigned to find it and sent results to the tracker. In the second strategy, the object detector and visual tracker are switched, and both produce the results to use at the next step. In the third strategy, the object detector is the base process. If the detector fails, a request will be sent to the tracker. They have tested system for drone detection and tracking on videos. As contribution, they have developed new architecture to detect and track drones on video with network which has been trained a few static images. As limitation, they have said the speed must be improved for real time application and accuracy must be improved too.
(Ovodov, 2020)	DSBI (R. Li et al., 2018), Angelina Braille Images Datsae (Ovodov, 2020)	<i>DSBI train and test</i> : FM on Point Base: 0.9994 FM on Character level: 0.9976	The author has developed an algorithm with some modification on RetinaNet architecture to recognize the Braille alphabet letters from the image. The letters are detected as point base and letter base. The point base detection has a higher f-measure value. As contribution, new dataset has been created and the images getting with a mobile phone can be used to

		<i>Train with DSBI+ Angelina, and test with Angelina:</i> FM on Point Base: 0.9991 FM on Character level:0.9981	recognize the text and results have been produced more quickly and accurately than the other studies. As limitation, the resultant class score can be given in AP metric to compare the general object detection algorithms, and at character level detection the FM values decrease.
(Hung et al., 2020)	BBBC038 (Caicedo et al., 2019), BBBC022 and BBC041 (Ljosa et al., 2012)	Nuclei detection: 82% mAP Cells with malarie: 78% mAP	They have used Keras R-CNN, which is based on Faster R-CNN for object detection in biological images. They have tried to detect two types of objects. First, they have detected cells from the image taken after staining the cell to highlight the DNA. And secondly, they have detected cells in blood smears that were taken from a patient with malarie parasite. As contribution, they have detected cell classes with different state of malaria parasite very quickly than traditional techniques. As limitation, the accuracy must be much more improved because the application area is human health.
(Wu et al., 2020)	Own dataset	57.6% mAP	They have used Mask R-CNN to detect mobile phones in a room for a wireless charging system. The study needs to find locations, numbers, and types of receivers in the Resonant Beam Charging system's coverage to start the charging process. After detection, these devices will be charged automatically by the system. They have focused on mobile phones. They have used different Intersection Over Union values (IoU), and different distances between the receiver and the charging system to measure accuracy. As contribution, their proposed system has decreased the detection time of mobile phones by one third. As limitation, accuracy must be improved and admitted dataset is needed.
(F. Han et al., 2020)	Own dataset	87.42% mAP	They have used CNN to detect objects underwater. According to some underwater imaging constraints as illumination and less image quality, object detection algorithms do not give satisfactory results. As contribution, they have compared their algorithms results with common algorithms and gotten high accuracy. They have said that their algorithm has enough accuracy to detect object for their underwater robot. As limitation, according to underwater imaginary challenging's the preprocessing procedures must be eliminated.
(J. Zhang et al., 2020)	GTSDDB (Houben et al., 2013)	<i>GTSDDB:</i>	They have developed an algorithm to detect the traffic signs based on Faster R-CNN with some additions. They have gotten features

	CCTSDB (J. Zhang et al., 2017) Lisa (Møgelmoose et al., 2012)	Recall 90.5% Precision 98.7% <i>CCTSDB:</i> Recall 83.62% Precision 99.7% <i>Lisa:</i> Recall 85.6% Precision 98.9%	with ResNet50 as a backbone network and run an attention mechanism on features to find essential features of signs. Then they have fed the features in different scales to Region Proposal Network. After detecting regions, they have predicted the traffic sign. As contribution, they have detected traffic signs which has different dimensions and different environmental conditions, and they have tested their system on different public dataset. As limitation, average accuracy is needed to be improved.
(Zhu et al., 2020)	Own dataset	88.1% mAP	They have developed a CNN-based algorithm with Feature Pyramid Network to detect objects on power transmission line. They have used multi-scale feature maps to get high accuracy. For the pre-train, MS COCO dataset has been used. As contribution, they have developed bounding box regression algorithm with orientation angle because the orientation of the objects is also important for the transmission lines. As limitation, accuracy must be improved.
(Kechaou et al., 2020)	PASCAL VOC	52.0% mAP on test without post-processing	They have used an encoder-decoder architecture for generic object detection. In the encoder, they have used Resnet for getting a feature map, and in the decoder, they have used CNN and LSTM to predict object class and bounding box. For each step in the decoding layer, they have found objects in the attended region. It repeats this process until each object is detected with one class and one bounding box in the image. As contribution, they have eliminated post-processing procedures on images. As limitation, the AP values of small objects are low so the accuracy must be improved.
(Sorano et al., 2020)	Soccer match video from Italian league and their annotated from Wyscout.	No result for object detection	They have developed system with ResNet for feature extraction and YOLOv3 for object detection to analyze the soccer videos for annotating the pass movements. Their project will be used as a guide for training footballers and examine the team's performance. In the study, YOLOv3 has been re-trained to detect the ball and the footballer and bidirectional LSTM has been used for the classification of the movement whether it is a pass or not. Their contribution is that they have trained and tested the system with matches under the same conditions (as the stadium, lights) and different conditions and they have detected pass movement. As limitation on object detection, accuracy must be improved to detect the ball and footballer.

(W. Han et al., 2020)	Waymo Open Dataset (Sun et al., 2020)	Pedestrian: 60.1% mAP Vehicle: 51.0% mAP	They have detected objects from 360° rotation Lidar sensor's 3D point cloud data on traffic with low latency and high accuracy. They have divided the data into slices, and after spatial pooling, each slice has been sent to LSTM. Then feature pyramid of data has been extracted. From feature pyramid, objects have been detected with SSD and non-maximum suppression. As contribution, they have reduced the latency due to Lidar sensor and by this way, they have developed a system which can be used for autonomous car. As limitations, object representation in 3D point cloud must be learned for getting more accurate results.
(Zhao et al., 2020)	Visual Genome (Krishna et al., 2017)	For object detection 7.49 mAP	They have developed an algorithm to caption objects with attributes on image. They have used Inception-v3 (Szegedy et al., 2016) as backbone network. They have run an image attribute extractor based on Inception-v3 without bounding box regression for getting objects attributes. And, they have run backbone network for detection region proposals and object class. Finally, the attributes and region features have been sent to LSTM for captioning. As contribution, they have trained an end-to-end system which detects the objects and captions them. As limitation, the accuracy must be improved for better captioning.
(Kristo et al., 2020)	UNIRI-TID (Kristo et al., 2020)	97.93% AP	They have developed an object detection system based on YOLOv3 and new dataset to detect the people who move the border or forbidden area illegally or be terrorists. They have used thermal videos recorded in different weather conditions with different person pose state and movement characteristics. As contribution, they have adapted the RGB object detection algorithm to thermal images and create new dataset which includes different weather conditions like rainy, foggy. As limitation, if the heatmap of the objects are affected environmental conditions the accuracy decreases, and system can be tricked due to thermal imagery challenges.
(Loey et al., 2020)	Medical Masks Dataset (<i>Medical Mask</i> , n.d.) (in study Kaggle version) Face Masks Dataset (<i>Face Masks</i> , 2020)	81% AP	They have tried to detect faces with the medical mask, which has been a part of our life with Covid-19. They have aimed to produce guidance to governments for controlling compliance with the mask-wearing rule. They have gotten the best results using Resnet-50, YOLOv2, and ADAM optimizer (Kingma & Ba, 2014). As contribution, they have developed mean IoU method to increase the accuracy and they have used object detection

to most important situation of our daily life. As limitation, the accuracy must be improved, and the number of the masked and unmasked face can be given.

4. Results and Discussions

With advances in deep learning and computer architecture, accuracy in object detection has increased, and processing time has been greatly reduced. Hereby as shown in part 3, object detection algorithms are applied in many research areas including health, country border security, epidemic disease, video/image captioning or annotation, transportation systems, autonomous vehicles, agriculture, damage assessment etc. Looking at the accuracy values, it can be said that the deep learning-based object detection algorithms provide solutions to many problems in different field.

In the line with the possibilities offered by deep learning, researchers need to decide whether they use common algorithms or develop new one. Because object properties such as different scales of object in same image, object density, the environment in which the object is placed etc. are challenging according to research area. Also, researchers need to decide the application will be offline or online. For online application, speed is important as accuracy. So, hardware must be also configured according to the computational needs.

As seen in Table 1, the accuracy must be improved for real field applications with eliminating limitations. Beside of this to develop the accuracy, admitted datasets are needed for many research areas. All the researching areas need to produce the results quickly so the researcher also focused on speeding up the computation and the speed of the algorithms must be reported.

5. Conclusion

In this study, common object detection algorithms, deep learning architectures and research in various fields using object detection have been chosen and briefly introduced. The methods, datasets and measurement metrics used in the reviews have been listed. This study aims to conduct literature research that will guide researchers who will work on object detection in their working area.

For future studies, researchers can focus on applying object detection to whole agriculture process because the quality of product is much more important according to global warming, shortage of resource and population crowd. For example, on hazelnut fields Erysiphe Pisi is causing Powdery Mildew disease which is the most damaging factor in recent times at North Region of Turkey and this disease should be detected and resolved immediately. For this task, an automatic disease detection and agricultural spraying system can be developed with unmanned aerial vehicles. Also, they can focus on reducing computational cost and speed up the process.

Researchers' Contribution Rate

All researchers have equal contribution rates.

Acknowledgement and/or disclaimers

There is no funding.

Conflict of Interest Statement

There is no conflict.

References

- Bahdanau, D., Chorowski, J., Serdyuk, D., Brakel, P., & Bengio, Y.** (2016). End-to-end attention-based large vocabulary speech recognition. *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 4945–4949. <https://doi.org/10.1109/ICASSP.2016.7472618>
- Caicedo, J. C., Goodman, A., Karhohs, K. W., Cimini, B. A., Ackerman, J., Haghghi, M., Heng, C. K., Becker, T., Doan, M., McQuin, C., Rohban, M., Singh, S., & Carpenter, A. E.** (2019). Nucleus segmentation across imaging experiments: the 2018 Data Science Bowl. *Nature Methods*. <https://doi.org/10.1038/s41592-019-0612-7>
- Cevikalp, H., Benligiray, B., & Gerek, O. N.** (2020). Semi-supervised robust deep neural networks for multi-label image classification. *Pattern Recognition*, *100*, 107164. <https://doi.org/https://doi.org/10.1016/j.patcog.2019.107164>

- Chen, J.-W., Lin, W.-J., Cheng, H.-J., Hung, C.-L., Lin, C.-Y., & Chen, S.-P.** (2021). A Smartphone-Based Application for Scale Pest Detection Using Multiple-Object Detection Methods. *Electronics*, 10(4), 372. <https://doi.org/10.3390/electronics10040372>
- Deng, J., Shi, S., Li, P., Zhou, W., Zhang, Y., & Li, H.** (2020). Voxel R-CNN: Towards High Performance Voxel-based 3D Object Detection. *ArXiv:2012.15712*.
- Elman, J. L.** (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211. [https://doi.org/https://doi.org/10.1016/0364-0213\(90\)90002-E](https://doi.org/https://doi.org/10.1016/0364-0213(90)90002-E)
- Face Masks.** (2020). <https://www.kaggle.com/andrewmvd/face-mask-detection>
- Fan, D. P., Ji, G. P., Sun, G., Cheng, M. M., Shen, J., & Shao, L.** (2020). Camouflaged object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR42600.2020.00285>
- Geiger, A., Lenz, P., & Urtasun, R.** (2012). Are we ready for autonomous driving? The KITTI vision benchmark suite. *2012 IEEE Conference on Computer Vision and Pattern Recognition*, 3354–3361. <https://doi.org/10.1109/CVPR.2012.6248074>
- Gers, F. A., Schmidhuber, J., & Cummins, F.** (1999). Learning to forget: continual prediction with LSTM. *1999 Ninth International Conference on Artificial Neural Networks ICANN 99. (Conf. Publ. No. 470)*, 2, 850–855 vol.2. <https://doi.org/10.1049/cp:19991218>
- Girshick, R., Donahue, J., Darrell, T., & Malik, J.** (2016). Region-Based Convolutional Networks for Accurate Object Detection and Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(1), 142–158. <https://doi.org/10.1109/TPAMI.2015.2437384>
- Girshick, Ross.** (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*.
- Hacıefendioğlu, K., Başağa, H. B., & Demir, G.** (2021). Automatic detection of earthquake-induced ground failure effects through Faster R-CNN deep learning-based object detection using satellite images. *Natural Hazards*, 105(1), 383–403. <https://doi.org/10.1007/s11069-020-04315-y>
- Han, F., Yao, J., Zhu, H., & Wang, C.** (2020). Underwater Image Processing and Object Detection Based on Deep CNN Method. *Journal of Sensors*, 2020, 1–20. <https://doi.org/10.1155/2020/6707328>
- Han, W., Zhang, Z., Caine, B., Yang, B., Sprunk, C., Alsharif, O., Ngiam, J., Vasudevan, V., Shlens, J., & Chen, Z.** (2020). *Streaming Object Detection for 3-D Point Clouds*. <http://arxiv.org/abs/2005.01864>
- Hochreiter, S., & Schmidhuber, J.** (1997). Long Short-Term Memory. *Neural Computation*. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Houben, S., Stallkamp, J., Salmen, J., Schlipsing, M., & Igel, C.** (2013). Detection of traffic signs in real-world images: The German traffic sign detection benchmark. *The 2013 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://doi.org/10.1109/IJCNN.2013.6706807>
- Hung, J., Goodman, A., Ravel, D., Lopes, S. C. P., Rangel, G. W., Nery, O. A., Malleret, B., Nosten, F., Lacerda, M. V. G., Ferreira, M. U., Rénia, L., Duraisingh, M. T., Costa, F. T. M., Marti, M., & Carpenter, A. E.** (2020). Keras R-CNN: library for cell detection in biological images using deep neural networks. *BMC Bioinformatics*, 21(1), 300. <https://doi.org/10.1186/s12859-020-03635-x>
- Indolia, S., Goswami, A. K., Mishra, S. P., & Asopa, P.** (2018). Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. *Procedia Computer Science*. <https://doi.org/10.1016/j.procs.2018.05.069>
- Jelodar, H., Wang, Y., Orji, R., & Huang, H.** (2020). Deep Sentiment Classification and Topic Discovery on Novel Coronavirus or COVID-19 Online Discussions: NLP Using LSTM Recurrent Neural Network Approach. *ArXiv:2004.11695*.
- Kechaou, A., Martinez, M., Haurilet, M., & Stiefelhagen, R.** (2020). Detective: An Attentive Recurrent Model for Sparse Object Detection. <http://arxiv.org/abs/2004.12197>
- Kingma, D. P., & Ba, J.** (2014). Adam: A

Method for Stochastic Optimization. <http://arxiv.org/abs/1412.6980>

Krishna, R., Zhu, Y., Groth, O., Johnson, J., Hata, K., Kravitz, J., Chen, S., Kalantidis, Y., Li, L. J., Shamma, D. A., Bernstein, M. S., & Fei-Fei, L. (2017). Visual Genome: Connecting Language and Vision Using Crowdsourced Dense Image Annotations. *International Journal of Computer Vision*. <https://doi.org/10.1007/s11263-016-0981-7>

Kristo, M., Ivacic-Kos, M., & Pobar, M. (2020). Thermal Object Detection in Difficult Weather Conditions Using YOLO. *IEEE Access*, 8, 125459–125476. <https://doi.org/10.1109/ACCESS.2020.3007481>

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet Classification with Deep Convolutional Neural Networks. *Commun. ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>

Law, H., & Deng, J. (2018). CornerNet: Detecting Objects as Paired Keypoints. *Proceedings of the European Conference on Computer Vision (ECCV)*, 734–750.

Lawrence, S., Giles, C. L., & Fong, S. (2000). Natural language grammatical inference with recurrent neural networks. *IEEE Transactions on Knowledge and Data Engineering*, 12(1), 126–140. <https://doi.org/10.1109/69.842255>

Le Cun, Y., Jackel, L. D., Boser, B., Denker, J. S., Graf, H. P., Guyon, I., Henderson, D., Howard, R. E., & Hubbard, W. (1989). Handwritten digit recognition: applications of neural network chips and automatic learning. *IEEE Communications Magazine*, 27(11), 41–46. <https://doi.org/10.1109/35.41400>

Le, T.-N., Nguyen, T. V, Nie, Z., Tran, M.-T., & Sugimoto, A. (2019). Anabran network for camouflaged object segmentation. *Computer Vision and Image Understanding*, 184, 45–56. <https://doi.org/https://doi.org/10.1016/j.cviu.2019.04.006>

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>

Lee, D.-H. (2020). CNN-based single object detection and tracking in videos and its application to drone detection. *Multimedia*

Tools and Applications. <https://doi.org/10.1007/s11042-020-09924-0>

Li, G., & Yu, Y. (2016). Visual Saliency Detection Based on Multiscale Deep CNN Features. *IEEE Transactions on Image Processing*, 25(11), 5012–5024. <https://doi.org/10.1109/TIP.2016.2602079>

Li, J., Zhao, R., Sun, E., Wong, J. H. M., Das, A., Meng, Z., & Gong, Y. (2020). High-Accuracy and Low-Latency Speech Recognition with Two-Head Contextual Layer Trajectory LSTM Model. *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 7699–7703. <https://doi.org/10.1109/ICASSP40776.2020.9054387>

Li, R., Liu, H., Wang, X., & Qian, Y. (2018). DSBI: Double-Sided Braille Image Dataset and Algorithm Evaluation for Braille Dots Detection. *Proceedings of the 2018 the 2nd International Conference on Video and Image Processing*.

Li, Y., Hou, X., Koch, C., Rehg, J. M., & Yuille, A. L. (2014). The Secrets of Salient Object Segmentation. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 280–287. <https://doi.org/10.1109/CVPR.2014.43>

Liu, Z., Li, Q., & Li, W. (2020). Deep layer guided network for salient object detection. *Neurocomputing*, 372, 55–63. <https://doi.org/https://doi.org/10.1016/j.neucom.2019.09.018>

Ljosa, V., Sokolnicki, K. L., & Carpenter, A. E. (2012). Annotated high-throughput microscopy image sets for validation. In *Nature Methods*. <https://doi.org/10.1038/nmeth.2083>

Loey, M., Manogaran, G., Taha, M. H. N., & Khalifa, N. E. M. (2020). Fighting against COVID-19: A novel deep learning model based on YOLO-v2 with ResNet-50 for medical face mask detection. *Sustainable Cities and Society*. <https://doi.org/10.1016/j.scs.2020.102600>

Medical Mask. (n.d.). Retrieved January 17, 2021, from <https://humansintheloop.org/medical-mask-dataset/>

Møgelmo, A., Trivedi, M. M., & Moeslund, T. B. (2012). Vision-based traffic sign detection

and analysis for intelligent driver assistance systems: Perspectives and survey. *IEEE Transactions on Intelligent Transportation Systems*.

<https://doi.org/10.1109/TITS.2012.2209421>

Ovodov, I. G. (2020). Optical Braille Recognition Using Object Detection CNN. *ArXiv:2012.12412*.

Öztemel, E. (2012). *Yapay Sinir Ağları* (3rd ed.). Papatya Yayıncılık Eğitim A.Ş.

Pascalvoc. (n.d.). Retrieved January 11, 2020, from <http://host.robots.ox.ac.uk/pascal/VOC/>

Pavan, G. S., Kumar, N., Karthik N., K., & Manikandan, J. (2020). Design of a Real-Time Speech Recognition System using CNN for Consumer Electronics. *2020 Zooming Innovation in Consumer Technologies Conference (ZINC)*, 5–10. <https://doi.org/10.1109/ZINC50678.2020.9161432>

Pi, Y., Nath, N. D., & Behzadan, A. H. (2020). Convolutional neural networks for object detection in aerial imagery for disaster response and recovery. *Advanced Engineering Informatics*, 43, 101009. <https://doi.org/https://doi.org/10.1016/j.aei.2019.101009>

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788.

Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>

Sardoğan, M., Özen, Y., & Tuncer, A. (2020). Faster R-CNN Kullanarak Elma Yaprağı Hastalıklarının Tespiti. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 1110–1117. <https://doi.org/10.29130/dubited.648387>

Skurowski, P., Abdulameer, H., Blaszczyk, J., Depta, T., Kornacki, A., & Koziel, P. (2017). *CHAMELEON*. <http://kgwisc.aei.polsl.pl/index.php/en/dataset/63-animal-camouflage-analysis>

Sorano, D., Carrara, F., Cintia, P., Falchi, F., & Pappalardo, L. (2020). *Automatic Pass Annotation from Soccer VideoStreams Based on Object Detection and LSTM*. <http://arxiv.org/abs/2007.06475>

Sun, P., Kretzschmar, H., Dotiwalla, X., Chouard, A., Patnaik, V., Tsui, P., Guo, J., Zhou, Y., Chai, Y., Caine, B., Vasudevan, V., Han, W., Ngiam, J., Zhao, H., Timofeev, A., Ettinger, S., Krivokon, M., Gao, A., Joshi, A., ... Angelov, D. (2020). Scalability in Perception for Autonomous Driving: Waymo Open Dataset. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2443–2451. <https://doi.org/10.1109/CVPR42600.2020.00252>

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR.2016.308>

Tassinari, P., Bovo, M., Benni, S., Franzoni, S., Poggi, M., Mammi, L. M. E., Mattoccia, S., Di Stefano, L., Bonora, F., Barbaresi, A., Santolini, E., & Torreggiani, D. (2021). A computer vision approach based on deep learning for the detection of dairy cows in free stall barn. *Computers and Electronics in Agriculture*, 182, 106030. <https://doi.org/10.1016/j.compag.2021.106030>

Tsai, W.-J., Huang, Z.-J., & Chung, C.-E. (2020). Joint Detection, Re-Identification, And Lstm In Multi-Object Tracking. *2020 IEEE International Conference on Multimedia and Expo (ICME)*, 1–6. <https://doi.org/10.1109/ICME46284.2020.9102884>

Turan, S., & Bilgin, G. (2019). Semantic nuclei segmentation with deep learning on breast pathology images. *2019 Scientific Meeting on Electrical-Electronics Biomedical Engineering and Computer Science (EBBT)*, 1–4. <https://doi.org/10.1109/EBBT.2019.8741715>

Ufldl Tutorial. (n.d.). UFLDL Tutorial. Retrieved December 24, 2020, from <http://ufldl.stanford.edu/tutorial/>

Vinayakumar, R., Soman, K. P., & Poornachandran, P. (2017). Applying

convolutional neural network for network intrusion detection. *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 1222–1228.

<https://doi.org/10.1109/ICACCI.2017.8126009>

Wang, L., Lu, H., Wang, Y., Feng, M., Wang, D., Yin, B., & Ruan, X. (2017). Learning to Detect Salient Objects with Image-Level Supervision. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3796–3805.

<https://doi.org/10.1109/CVPR.2017.404>

Wu, A., Zhang, Q., Fang, W., Deng, H., Jiang, S., & Liu, Q. (2020). *Mask R-CNN Based Object Detection for Intelligent Wireless Power Transfer*.

<http://arxiv.org/abs/2004.10021>

Xiao, H., Xu, J., & Shi, J. (2020). Exploring diverse and fine-grained caption for video by incorporating convolutional architecture into LSTM-based model. *Pattern Recognition Letters*, 129, 173–180.

<https://doi.org/https://doi.org/10.1016/j.patrec.2019.11.003>

Yan, Q., Xu, L., Shi, J., & Jia, J. (2013). Hierarchical Saliency Detection. *CVPR 2013*.

Yang, C., Zhang, L., Lu, H., Ruan, X., & Yang, M.-H. (2013). Saliency detection via graph-based manifold ranking. *Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference On*, 3166–3173.

Yuan, D., Li, X., He, Z., Liu, Q., & Lu, S. (2020). Visual object tracking with adaptive structural convolutional network. *Knowledge-Based Systems*, 194, 105554.

<https://doi.org/https://doi.org/10.1016/j.knsys.2020.105554>

Zhang, J., Huang, M., Jin, X., & Li, X. (2017). A real-time Chinese traffic sign detection algorithm based on modified YOLOv2. *Algorithms*.

<https://doi.org/10.3390/a10040127>

Zhang, J., Xie, Z., Sun, J., Zou, X., & Wang, J. (2020). A Cascaded R-CNN with Multiscale Attention and Imbalanced Samples for Traffic Sign Detection. *IEEE Access*.

<https://doi.org/10.1109/ACCESS.2020.2972338>

Zhang, W., Xu, L., Li, Z., Lu, Q., & Liu, Y.

(2016). A Deep-Intelligence Framework for Online Video Processing. *IEEE Software*, 33(2), 44–51.

<https://doi.org/10.1109/MS.2016.31>

Zhao, D., Chang, Z., & Guo, S. (2020). Cross-scale fusion detection with global attribute for dense captioning. *Neurocomputing*.

<https://doi.org/10.1016/j.neucom.2019.09.055>

Zhu, J., Guo, Y., Yue, F., Yuan, H., Yang, A., Wang, X., & Rong, M. (2020). A deep learning method to detect foreign objects for inspecting power transmission lines. *IEEE Access*.

<https://doi.org/10.1109/ACCESS.2020.2995608>

8

Araştırma Makalesi

Ticari gemilerde operasyonel elektriksel gücün tahmininde makine öğrenmesi yaklaşımı: şaft jeneratörü güç tahmini uygulaması

Tayfun Uyanık

Gemi Makineleri İşletme Mühendisliği Bölümü, Denizcilik Fakültesi, İstanbul Teknik Üniversitesi,
Tuzla, İstanbul, Türkiye

*Correspondence: uyanikt@itu.edu.tr

DOI:10.51513/jitsa.993058

Özet: Son yıllarda uluslararası denizcilik ve çevre otoritelerince denizcilik sektöründeki emisyonların azaltılması için son derece radikal kararlar alınmaktadır. Şirketler yürürlüğe konulan kuralları uygulamak için fayda-maliyet oranı bakımından etkin yaklaşımlarla enerji verimliliğini arttırmayı amaçlamaktadır. Bu kapsamda gemi enerji verimliliğinin ve emisyonların belirlenmesi için literatürde çeşitli yaklaşımlar oluşturulmuştur. Özellikle son beş yılda makine öğrenmesi yöntemlerinin farklı alanlarda uygulamalarının başarılı sonuçlar vermesi üzerine bu yöntemler denizcilik sektöründe emisyonların belirlenebilmesi adına da kullanılmaya başlanmıştır. Gemide yakıt tüketimi emisyonun büyük bir bölümünü oluşturmaktadır. Bu konuda literatürde çok sayıda çalışma mevcuttur. Bu çalışmada ise gemilerde genellikle seyir sırasında birden fazla sayıda jeneratörün çalıştırılması yerine operasyonel iş ve işlemler için kullanılan şaft jeneratörünün gücü makine öğrenmesi uygulamaları vasıtasıyla tespit edilmiştir. Çalışmada bir konteyner gemisinden alınan 750 günlük veri seti kullanılmıştır. Alınan veri seti makine öğrenmesi yöntemleri için uygun hale getirilmiştir. Bu aşamada veri seti eğitim ve test verisi olarak bilgisayar tarafından rastgele seçilerek iki kısma ayrılmıştır. Eğitim verisi ile algoritmalar eğitilmiş, test verisi ise algoritmalara öğretilmemiş ve tahmin işlemi sırasında algoritma başarılarının ölçülebilmesi adına saklanmıştır. Yapılan tahminler sonucunda Çoklu Doğrusal Regresyon algoritmasının şaft jeneratörünün elektriksel gücünün tahmini işleminde çalışmada incelenen diğer algoritmalarından daha başarılı sonuçlar verdiği tespit edilmiştir.

Anahtar Kelimeler: Gemi kaynaklı emisyonlar, enerji verimliliği, makine öğrenmesi, şaft jeneratörü

Machine learning approach to estimating operational electrical power on trade vessels: an application for shaft generator power prediction

Abstract: In recent years, extremely radical decisions have been taken by international maritime and environmental authorities to reduce emissions in the maritime sector. Companies aim to increase energy efficiency with effective approaches in terms of cost-benefit ratio to implement the rules that have been put into effect. In this context, various approaches have been developed in the literature to determine ship energy efficiency and emissions. Especially in the last five years, applications of machine learning methods in different fields have yielded successful results, and these methods have started to be used to determine emissions in the maritime sector. Fuel consumption onboard accounts for a large part of emissions. There are many studies in the literature on this subject. In this study, the power of the shaft generator is generally used for operational work and operations instead of running more than one generator during the cruise, has been determined through machine learning applications. A data set for 750 days from a container ship was used in the study. The received data set has been made suitable for machine learning methods. At this stage, the data set was randomly selected by the computer as training and test data and divided into two parts. Algorithms were trained with the training data, while the test data was not taught to the algorithms and stored to measure the success of the algorithms during the estimation process. As a result of the estimations, it has been determined that the Multiple Linear Regression algorithm gives more successful results than the other algorithms examined in the study in the estimation of the electrical power of the shaft generator.

Key words: Vessel based emissions, energy efficiency, machine learning, shaft generator.

1. Giriş

Denizcilik sektörü dünya ticaretinde hayati öneme sahiptir ve gündün güne önemi artmaktadır (Chengpeng ve ark., 2021). Özellikle son 10 yılda sektörde oluşan talebin karşılanabilmesi adına deniz ticareti üzerindeki yoğunluk giderek artmaktadır (Jin ve ark., 2019). Bu yoğunluğun neden olduğu emisyonların azaltılması adına Uluslararası Denizcilik Örgütü (IMO) tarafından çeşitli kurallar gündeme getirilmiştir (Bilgili, 2021; Harilaos ve ark., 2021; Paula, 2021). Sektörde yer alan denizcilik şirketleri bu kuralların getirdiği yükümlülükleri yerine getirebilmek adına çeşitli araştırma ve geliştirme çalışmalarına yönelmiştir (Alexey, 2014). Bu çalışmalarda akla gelen ilk yaklaşım mevcut sistemlerin yenilenmesi olsa da yenileme işlemi maliyet bakımından önemli bir handikap da barındırmaktadır (Saim ve Yercan, 2021). Bu yüzden denizcilik şirketleri var olan sistemlerin verimliliğinin belirlenmesi ve bu sistemlerin daha verimli kullanılması yolu ile IMO'nun emisyon kurallarını sağlamayı amaç edinmişlerdir (Andrew ve ark., 2020). Gemi enerji verimliliğinin artırılması için öncelikle verimlilik durumu tespit edilmeli, analiz edilebilecek seviyede veri elde edilmeli ve sistem geliştirmeleri bunun üzerine bina edilmelidir. Gelişen teknolojinin son yıllarda denizcilik sektörü üzerinde uygulamalarının artması ve gemilerden veri elde edilmesinin kolaylaşması sayesinde gemilerden sefer verileri elde edilmeye başlanmıştır (Pavlos ve Nikos, 2021). Bu veriler sefer rotası kapsamında karşılaşılan meteorolojik veriler, çeşitli dış faktörler, makine sensörlerinden alınan bilgiler, geminin iç dinamikleri ile ilgili bilgiler gibi çeşitli tipte verileri içerebilmektedir. Bu verilerin elde edilmesinde yaşanan gelişmelerden hareketle geminin enerji verimliliğinin bulunmasında önemli mesafe kat edilmiştir denilebilir (Chi ve ark. 2019). Gemi ve liman enerji verimliliğini arttırmayı hedefleyen bir çalışmada makine öğrenmesi yöntemlerinden faydalanılmış, gemiden ve geminin yanışığı limandan 15 farklı veri alınarak ve bu veriler analiz edilerek gemi ve liman enerji verimliliğinin artırılması hedeflenmiştir. Analiz sonucunda en önemli veriler belirlenerek enerji verimliliğinin bu verilerden hareketle artırılması çalışması

yapılmıştır (Peng ve ark., 2020). Gemilerde enerji verimliliği uygulamalarında sefer verileri sıklıkla kullanılmaktadır. Bu kapsamda hazırlanan bir çalışmada bir dökme yük gemisinin iki yıllık sefer verisi analiz edilmiştir. Veri seti yardımıyla yapay sinir ağı eğitilmiş ve tahmin işlemi yapılmıştır. Benzetim sonuçları veriye dayalı yöntemlerin klasik yöntemlere göre başarı anlamında daha üstün olduğunu ortaya koymuştur (Tran, 2021). Gemilerin operasyonel verimliliklerinin artırılması için veri toplama sistemlerinden faydalanılmasını öneren bir çalışmada veri setindeki verilerin birbiri ile ilişkisinden faydalanılarak ana makine çalışma modu için bir karar destek modeli geliştirilmiştir (Khanh ve Perera., 2021). Makine öğrenmesi yöntemlerinin gerçek gemi verileri üzerine uygulanarak dinamik yakıt tüketiminin tahmin edilmesini amaçlayan bir çalışmada kurulan modeller sayesinde enerji verimliliği optimizasyonu yapılabilmektedir (Ahlgren ve ark., 2019). İki farklı gemide yakıt tüketimi tahminini amaçlayan bir çalışmada veri seti olarak öğlen raporları ve makine sensörlerinden alınan veriler kullanılmıştır. Ana makine sensör sisteminin veri toplamada önemli bir avantaj sunduğu, veri toplamak için harcanan süreyi azalttığı tespit edilmiştir. Kullanılan makine öğrenmesi modelleriyle de gemilerin yakıt tüketimi başarılı bir şekilde tahmin edilebilmiştir (Gkerekos ve ark., 2019). Ticari gemiler için yakıt tüketimi seferde oluşabilecek giderlerin en önemlisidir. Son yıllarda yapılan çalışmalarda elde edilen bulgular ticari gemilerin sefer boyunca gün bazında tükettiği yakıtın tespiti, emisyonlar, enerji verimliliği hesaplanması, harcanan yakıt miktarı ve gidilen yol arasındaki ilişkilerin bilinmesi gibi konularda önemli mesafe alındığını ortaya çıkarmıştır (Andrea ve ark., 2019; Yuanqiao ve ark. 2020). Gemilerde ana enerji kaynağı olan yakıtın tüketilmesi esnasında verimli ve doğru davranışlar ticari gemilerin sürdürülebilirliğini arttırmaktadır. Bu kapsamda enerji verimliliğinin artırılması adına seyir durumunda iken operasyonel işlerde 2 veya 3 jeneratör çalıştırılması yerine gemide ana makinede üretilmiş enerjinin şaft vasıtasıyla bir jeneratöre verilmesi yöntemi son yıllarda tercih edilir hale gelmiştir (Jan, 2014). Gemide jeneratörlerin toplam yakıtın yaklaşık %10-15'lik bir bölümünü harcadığı literatürde

incelen çalışmalar vasıtasıyla bilinmektedir (Aris ve ark., 2017). Bu miktar kayda değer bir orandır. Sefer sırasında harcanan yakıt sayesinde şaft jeneratörü vasıtasıyla üretilen elektriksel enerjinin tahmini ve verimli kullanılması sayesinde gemide enerji verimliliği artırılabilir.

Bu çalışmada son yıllarda çok farklı alanlara uygulanıp başarılı sonuçlar elde edilen ve böylelikle uygulama alanı yaygınlaşan makine öğrenmesi yöntemleri ile ticari bir gemide 750 günlük gerçek sefer verilerinden hareketle gemide kullanılan şaft jeneratörü tarafından üretilen elektriksel güç tahmin edilmiştir. Veri seti eğitim (%66) ve test verisi (%33) olarak bilgisayar tarafından rastgele seçilerek iki kısma ayrılmıştır. Eğitim verisi olarak seçilen kısım ile makine öğrenmesi yöntemlerine öğretilerek tahmin modelleri geliştirilmesi sağlanmıştır. Bu modeller ile yapılan tahminlerin doğruluğunun tespit edilebilmesi adına test verileri kullanılmıştır. Bu veriler algoritmalara öğretilmemiş ve saklanmıştır. Makine öğrenmesi yöntemlerinin kullanılması için Python programlama dilinin Spyder 3.0 ara yüzü kullanılmıştır. Bu ara yüz sayesinde Çoklu Doğrusal Regresyon (Aline ve ark., 2021), Ridge (Dai ve ark., 2020), Destek Vektör Makinesi (Kanka ve Samuel, 2021), Rastgele Orman (Zhen ve ark., 2021), Karar Ağacı (Tariku ve ark., 2020) ve Gradient Boosting (Nitin ve ark., 2021) isimli makine öğrenmesi yöntemleri kullanılarak bir konteyner gemisi için şaft jeneratörünün elektriksel gücü tahmin edilmiştir. Tahminlerin karşılaştırılabilmesi adına Ortalama Mutlak Hata (Laura ve ark., 2018) ve Kök Ortalama Kare Hata (Martin ve ark., 2020) isimli hata metrikleri kullanılmıştır. Benzetim çalışmasında yapılan tahminler başlangıçta istenen başarıyı sağlayamamıştır. Bu nedenle başarısı düşük algoritmaların parametreleri ayarlanarak tahmin başarısı artırılmıştır. Çalışma sonucunda Çoklu

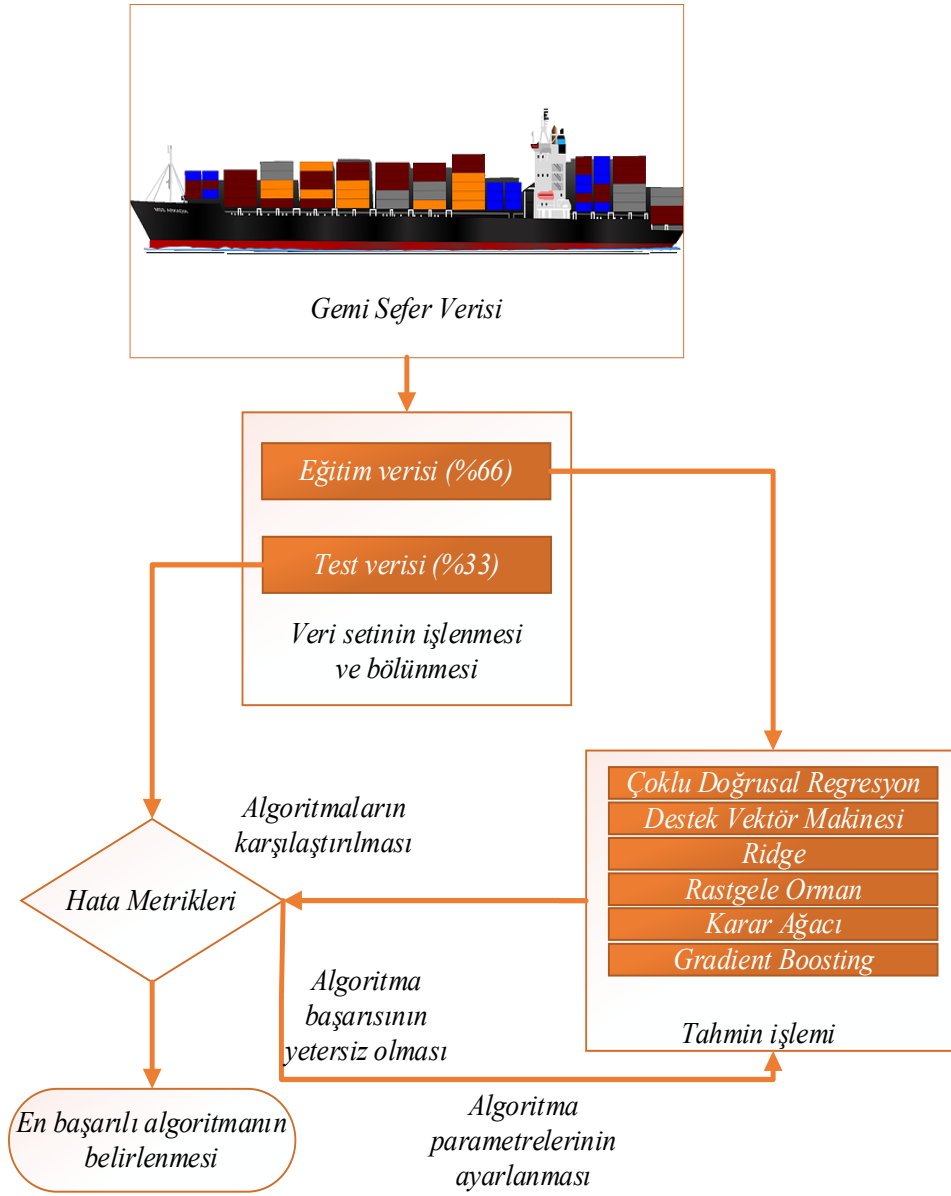
Doğrusal Regresyon algoritmasının gemi şaft jeneratörünün elektriksel gücünün tahmin edilmesinde diğer yöntemlerden daha başarılı olduğu ortaya çıkmıştır. Çalışma sonunda elde edilen bulgulardan hareketle gemilerde şaft jeneratörünün elektriksel güç tahmininin makine öğrenmesi algoritmaları ile başarılı bir şekilde tahmin edilebileceği sonucuna da varılabilir. Bu sayede ilerleyen yıllarda bu bağlamda enerji verimliliği modelleri kurulabilir ve gemi enerji verimliliğinin artırılmasına katkı da sunulabilir.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir; ikinci bölüm materyal ve metot üzerine kurgulanmıştır, üçüncü bölümde yapılan tahmin çalışması ve elde edilen sonuçlar yer almıştır. Çalışmanın dördüncü ve son bölümünde ise benzetim çalışmasında elde edilen bulgular değerlendirilmiştir.

2. Materyal ve Yöntemler

2.1. Çalışmada izlenen yöntem

Bu çalışma ticari bir gemide şaft jeneratörü elektriksel gücünün makine öğrenmesi yöntemleri ile tahmin edilmesi üzerine oluşturulmuştur. Çalışma kapsamında bir konteyner gemisinden 750 günlük sefer verisi alınmıştır. Veri seti alınıp işlendikten sonra makine öğrenmesi algoritmalarının üzerinde çalışabileceği hale getirilmiştir. Bu noktada veri seti eğitim ve test verisi olarak iki kısma ayrılmış, eğitim verileri algoritmalarla öğretilerek tahmin modelleri geliştirilmiştir. Test verileri ise algoritma başarılarının tespitinde kullanılmak üzere saklanmıştır. Çalışma kapsamında şaft jeneratörü elektriksel gücü tahmini başarısını ölçebilmek adına hata metrikleri kullanılmıştır. Bu sayede algoritmaların tahmin başarıları sayısal olarak ifade edilebilmiş ve birbirileriyle karşılaştırılabilmiştir. Çalışma kapsamında yapılan işlemler Şekil 1'de gösterilmiştir.



Şekil 1. Çalışmanın metodolojisi.

2.2. Veri setinin özeti

Çalışmada ticari amaçla kullanılan 318 metre uzunluğa 42 metre genişliğe ve 8,4 metre draфта sahip bir konteyner gemisinin 750 günlük sefer verisi üzerinde makine öğrenmesi algoritmaları çalıştırılmıştır. Bu veri gemide yer alan çeşitli sensörlerden elde edilmiştir. Veri setinde 24

farklı değişken mevcuttur. Bu değişkenler silindirik sıcaklıkları, ana makina ceket soğutma suyu sıcaklık değerleri, yakıt giriş sıcaklığı, yakıt giriş debisi, ana makina gücü, yakıt tüketimi ve şaft jeneratörü gücü gibi değerlerdir. Kullanılan veri setinin istatistiksel özeti tablo 1’de verilmiştir.

Tablo 1. Veri setinin istatistiksel özeti

	Adet	Ortalama değer	En küçük değer	En büyük değer	Standart Sapma
Günlük yakıt tüketimi (t)	750	48,73	17,3	151,7	35,71
Ana makine gücü (kW)	750	10970,6	2781,4	30872	8365,2
Ceket soğutma suyu sıcaklığı (°C)	750	89,5	85,1	94,12	9,5
Ana makine yakıt giriş sıcaklığı (°C)	750	67,8	63,9	71,74	6,51
Şaft jeneratörü gücü (kW)	750	814,76	95	1740	1317,45
...

2.3. Makine öğrenmesi algoritmaları


a) Çoklu doğrusal regresyon

Makine öğrenmesi algoritmalarının en bilinen yöntemlerinden olan çoklu doğrusal regresyon (ÇDR) algoritmasında bağımsız değişkenlerin belirli katsayılarla çarpılarak toplanması sonucunda bağımlı değişken elde edilir. Bu algoritma ile ilgili denklem aşağıda verilmiştir. Denklem 1’de w değerleri sabitleri, x değerleri bağımsız değişkenleri ifade ederken y değeri ise bağımlı değişkeni göstermektedir (Aline ve ark., 2021).

$$w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n = y \quad (1)$$

b) Destek vektör makinesi

Destek vektör makinesi (DVM) denetimli makine öğrenmesi yöntemlerinden biridir (Kanka ve Samuel, 2021). Bu algoritmada amaç yapılan tahminlerin önceden belirlenen aralık içinde olmasını sağlamaktır. Bu aralığa destek vektörü de denmektedir. Bu algoritma Şekil 2’de gösterilmiştir. Şekil incelendiğinde ϵ değerleri hata için izin verilen aralığı ifade etmektedir. Grafikte belirlenen destek vektörleri mavi renkte uzun çizgiler olarak gösterilmiş, kabul edilebilir hata oranına sahip tahminler mavi noktalarla belirtilmiştir. Destek vektörlerinin dışında kalan başarısız tahmin değerleri ise kırmızı noktalarla gösterilmiştir.




Şekil 2. Destek vektör makinesi.

c) Ridge yöntemi

Ridge (R) yöntemi katsayı tahmininde kullanılan bir yöntemdir. Bu yöntemde tahmin edicilerin yaptığı tahminlerin hata değerinin sifıra yaklaştığı modeller üretilmeye çalışılır. Kurgusu bakımından doğrusal regresyon algoritmasına benzer ancak katsayılar en küçük kareler yöntemi yerine ceza değeri uygulanarak belirlenmeye çalışılır (Dai ve ark., 2020).

d) Karar ağacı algoritması


Karar ağaçları (KA), hem regresyon hem de sınıflandırma modelleri üzerine kullanılan bir algoritmadır. Karar ağaçları, özellik ve hedefe göre değişen karar düğümleri ve yaprak düğümlerden oluşmaktadır. Bu yöntem insan düşünme yöntemine benzerliği ile diğer algoritmalarından ayrılmaktadır. Şekil 3’te karar ağacı yöntemi gösterilmiştir.



Şekil 3. Karar ağacı yöntemi

e) Rastgele orman algoritması

Rastgele orman (RO) yönteminde çok sayıda karar ağaçlarının oluşturduğu bir yapı düşünülmelidir. Bu yapı üzerinde farklı ağaçların tahminleri bir araya getirilir ve ortalaması alınarak nihai tahmin değerine ulaşılır (Zhen ve ark., 2021). Bu yapı Şekil 4'te gösterilmiştir.



Şekil 4. Rastgele orman algoritması

f) Gradient boosting algoritması

Gradient boosting (GB) yöntemi regresyon ve sınıflandırma konularında sıklıkla kullanılan bir yöntemdir. Bu yöntemde yapılan tahmin değeri için kullanılan parametre ağırlıkları her tahmin için değiştirilmek yerine bir önceki yapılan tahminlerdeki hata ile karşılaştırarak sonuca gidilmeye çalışılır (Nitin ve ark., 2021).

2.4. Hata metrikleri

a) Ortalama mutlak hata

Bu hata metriği bulunurken her indis için gerçek değer ile tahmin edilen değer arasındaki farkın mutlak değeri bulunur. Bulunan bu değerlerin

ortalaması ortalama mutlak hata (OMH) değerini verir. Denklem 2'de ortalama mutlak hatanın bulunması gösterilmiştir.

$$OMH = \frac{1}{n} \sum_{i=1}^n |g_i - t_i| \quad (2)$$

Bu denklemde i değeri indis numarasını, g değeri gerçek değerleri ifade ederken t değeri ise tahmin edilen değerleri ifade eder.

b) Kök ortalama kare hata

Makine öğrenmesi modellerinin başarısı incelenirken sıklıkla kullanılan yöntemlerden biridir. Bu yöntemde tahmin edilen değerler ile gerçek değerler arasındaki farkların kareleri alınır ve toplanır. Bu toplamın karekökü alınır. Son olarak ortalaması bulunarak kök ortalama kare hata (KOKH) değeri bulunmuş olur. Bu işlem Denklem 3'te gösterilmiştir.

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (g_i - t_i)^2} \quad (3)$$

Bu denklemde i değeri indis numarasını ifade ederken g değeri gerçek değerleri ifade eder. Denklemde t değeri ise tahmin edilen değerleri ifade eder.

3. Şaft Jeneratörü Elektriksel Güç Tahmini Benzetim Sonuçları

Konteyner gemisi şaft jeneratörü elektriksel güç tahmini için öncelikle veri seti işlenip makine öğrenmesi algoritmaları için uygun hale getirilmiştir. Daha sonra bilgisayar tarafından eğitim ve test verisi olarak veri seti iki kısma ayrılmıştır. İlk kısım olan 500 satırlık eğitim verisi bölümü algoritmalara tahmin modeli oluşturulabilmesi amacıyla öğretilmiştir. Kalan 250 satırlık test verisi ise algoritmalar tarafından eğitim verisi ile kurulan modellerin başarısının incelenmesi adına saklanmıştır. Çalışmanın bir sonraki aşamasında algoritmalar tarafından şaft jeneratörü gücü tahmini yapılmıştır. Tahmin çalışmasının ilk safhasında bazı algoritmalar tahmin edici seviyede bir başarı sağlayamamıştır. Bu nedenle algoritmaların parametreleri optimize edilerek tahmin işlemi tekrarlanmıştır. Çalışmada elde edilen hata metrikleri Tablo 2'de verilmiştir. Çalışmanın ilk safhasında optimize edilen algoritma parametreleri ise Tablo 3'te görülmektedir. Algoritmaların yaptığı


tahminlerin 30 günlük bir karşılaştırılması ise Şekil 5'te yer almıştır.

Tablo 2. Hata metrikleri

	ÇDR	DVM	R	KA	RO	GB
OMH	0,0338	0,3141	0,1889	0,2873	0,282	0,3248
KOKH	0,0973	0,4101	0,3293	0,3541	0,347	0,3944

Tablo 3. Algoritma parametreleri

Algoritma	Parametre değeri
Çoklu doğrusal regresyon	pozitif=Doğru
Destek vektör makinesi	çekirdek='doğrusal'
Ridge	çözücü='svd', alpha = 0.4
Karar Ağacı	maksimum derinlik = 27
Rastgele orman	tahmin edici sayısı=76, minimum örnek bölümü = 12
Gradient Boosting	kayıp='ls'



Şekil 5. Algoritma tahminlerinin karşılaştırılması

4. Sonuçlar ve öneriler

Bu çalışmada ticari amaçla kullanılan bir konteyner gemisinde sefer sırasında ihtiyaç duyulan elektriksel güç ihtiyacının şaft jeneratörü ile karşılandığı bu sistemde geminin operasyonel güç ihtiyacının makine öğrenmesi algoritmaları ile tahmini yapılmıştır. Tahmin işlemi sonucunda Çoklu Doğrusal Regresyon yönteminin tahmin sonuçlarından görüleceği üzere bu veri seti özelinde şaft jeneratörü elektriksel gücünü tahmin etmede ele alınan diğer makine öğrenmesi algoritmalarından daha başarılı olduğu ortaya çıkmıştır.

Yapılan tahminler gemilerde şaft jeneratörünün elektriksel gücünün tahmininde makine öğrenmesi algoritmalarının işlevsel olabileceğini göstermiştir. Ayrıca makine öğrenmesi yöntemleri ile kurulan tahmin modeli sayesinde elektriksel yükün önceden tahmin edilebileceği, bu sayede gemide sefer esnasında ani bir yüklenme için oluşabilecek elektriksel çökmelere karşı önlem alınabileceği ve elektriksel yük davranışının tahmin edilebilmesi sayesinde fazladan güç üretmek yerine yapılacak bir güç üretimi optimizasyonu sayesinde elektriksel güç üretmek için harcanan yakıt miktarından tasarruf edilebileceği ve sürdürülebilir bir denizcilik için ve Uluslararası Denizcilik Örgütü tarafından konulan emisyon kurallarını sağlamaya yönelik olumlu bir adım atılabileceği bulguları elde edilmiştir.

Destek ve Teşekkür Beyanı

Teşekkür edilecek bir kurum ya da kuruluş bulunmamaktadır.

Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kişi ya da kurum ile çıkar çatışması bulunmamaktadır.

Referanslar

Ahlgren F., Mondejar M.E., Thern M. (2019). Predicting Dynamic Fuel Oil Consumption on Ships with Automated Machine Learning, *Energy Procedia*, 158, 6126-6131, 1876-6102, doi: 10.1016/j.egypro.2019.01.499.

Alexey V. P. (2014). Innovation and design of cruise ships, *Pacific Science Review*, 16, 4, 280-282, 1229-5450, doi: 10.1016/j.pscr.2015.02.001.

Aline F. S., Nicolau A. C., André D. S. B., José E. S., Amauri G., Noé C., Bismarck L. S. (2021). Multiple linear regression approach to predict tensile properties of Sn-Ag-Cu (SAC) alloys, *Materials Letters*, 304, 130587, 0167-577X, doi: 10.1016/j.matlet.2021.130587.

Andrea C., Luca O., Francesco B., Francesca C., Mehmet A., Stefano S. (2019). Data-driven ship digital twin for estimating the speed loss caused by the marine fouling, *Ocean Engineering*, 186, 106063, 0029-8018, doi: 10.1016/j.oceaneng.2019.05.045.

Andrew C. T., Irina H., Vasco S. R., Joseph S. (2020). Maritime container shipping: Does coopetition improve cost and environmental efficiencies?. *Transportation Research Part D: Transport and Environment*, 87, 102507, 1361-9209, doi: 10.1016/j.trd.2020.102507.

Aris P., Anders H. M., Tim C. M. (2017). Applying Multi-Class Support Vector Machines for performance assessment of shipping operations: The case of tanker vessels, *Ocean Engineering*, 140, 1-6, 0029-8018, doi: 10.1016/j.oceaneng.2017.05.001.

Bilgili L. (2021). Life cycle comparison of marine fuels for IMO 2020 Sulphur Cap. *Science of The Total Environment*, Volume 774, 145719, 0048-9697, doi: 10.1016/j.scitotenv.2021.145719.

Chengpeng W., Yinxiang Z., Di Z., Tsz L. Y. (2021). Identifying important ports in maritime container shipping networks along the Maritime Silk Road. *Ocean & Coastal Management*, 211, 105738, 0964-5691, doi: 10.1016/j.ocecoaman.2021.105738.

Chi Z., Di Z., Mingyang Z., Wengang M. (2019). Data-driven ship energy efficiency analysis and optimization model for route planning in ice-covered Arctic waters, *Ocean Engineering*, 186, 106071, 0029-8018, doi: 10.1016/j.oceaneng.2019.05.053.

Dai X., Chen H., Seyed A. B., Masoud S., Mohammad A. (2019). Statistical estimation the thermal conductivity of MWCNTs-SiO₂/Water-EG nanofluid using the ridge regression method, *Physica A: Statistical Mechanics and its Applications*, 537, 122782, 0378-4371, doi: 10.1016/j.physa.2019.122782.

- Gkerekos C., Lazakis I., Theotokatos G.** (2019). Machine learning models for predicting ship main engine Fuel Oil Consumption: A comparative study, *Ocean Engineering*, 188, 106282, 0029-8018, doi: 10.1016/j.oceaneng.2019.106282
- Harilaos N. P., Thalys Z., Sotiria L.** (2021). A comparative evaluation of market based measures for shipping decarbonization. *Maritime Transport Research*, 2, 100019, 2666-822X, doi: 10.1016/j.martra.2021.100019.
- Jan K.** (2014). Ship's Propulsion Neural Controller Main Engine-Pitch Propeller-Shaft Generator, *IFAC Proceedings Volumes*, 47, 1, 905-912, 1474-6670, 9783902823601, doi: 10.3182/20140313-3-IN-3024.00067.
- Jin S. P., Young-Joon S., Min-Ho H.** (2019). The role of maritime, land, and air transportation in economic growth: Panel evidence from OECD and non-OECD countries. *Research in Transportation Economics*, 78, 100765, 0739-8859, doi: 10.1016/j.retrec.2019.100765.
- Kanka G., Samuel G. L.** (2021). Support vector machine regression for predicting dimensional features of die-sinking electrical discharge machined components, *Procedia CIRP*, 99, 508-513, 2212-8271, doi: 10.1016/j.procir.2021.03.109.
- Khanh Q. B., Perera L.P.** (2021). Advanced data analytics for ship performance monitoring under localized operational conditions, *Ocean Engineering*, 235, 109392, 0029-8018, doi: 10.1016/j.oceaneng.2021.109392.
- Laura F. P., Fermin M., Martín G. R., Teresa L.** (2018). Dynamic mean absolute error as new measure for assessing forecasting errors, *Energy Conversion and Management*, 162, 176-188, 0196-8904, doi: 10.1016/j.enconman.2018.02.030.
- Martin Ć., Shady H. E. A. A., Ahmed F. Z.** (2020). On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function, *Energy Conversion and Management*, 210, 112716, 0196-8904, doi: 10.1016/j.enconman.2020.112716.
- Nitin D., Babita S., Chalak H.D.** (2021). Gradient boosting-based regression modelling for estimating the time period of the irregular precast concrete structural system with cross bracing, *Journal of King Saud University-Engineering Sciences*, 1018-3639, doi: 10.1016/j.jksues.2021.08.004.
- Pavlos K., Nikos T.** (2021), Data-driven modelling of ship propulsion and the effect of data pre-processing on the prediction of ship fuel consumption and speed loss. *Ocean Engineering*, 222, 108616, 0029-8018, doi: 10.1016/j.oceaneng.2021.108616.
- Paula S. Á.** (2021). From maritime salvage to IMO 2020 strategy: Two actions to protect the environment, *Marine Pollution Bulletin*, 170, 112590, 0025-326X, doi: 10.1016/j.marpolbul.2021.112590.
- Peng Y., Huakun L., Xiangda L., Jian H., Wenyuan W.** (2020). Machine learning method for energy consumption prediction of ships in port considering green ports, *Journal of Cleaner Production*, 264, 121564, 0959-6526, doi: 10.1016/j.jclepro.2020.121564.
- Saim T.K., Yercan F.** (2021). Comparative Cost-Effectiveness Analysis of Arctic and International Shipping Routes: A Fuzzy Analytic Hierarchy Process, *Transport Policy*, 0967-070X, doi: 10.1016/j.tranpol.2021.08.015.
- Tariku S. T., Gang X., Zhishuai L., Hao T., Zhen S., Bin H., Heruye M. M.** (2021). Traffic Congestion Prediction using Decision Tree, Logistic Regression and Neural Networks, *IFAC-Papers On Line*, 53, 5, 512-517, 2405-8963, doi: 10.1016/j.ifacol.2021.04.138.
- Tran T.A.** (2021). Comparative analysis on the fuel consumption prediction model for bulk carriers from ship launching to current states based on sea trial data and machine learning technique, *Journal of Ocean Engineering and Science*, 2468-0133, doi: 10.1016/j.joes.2021.02.005.
- Yuanqiao W., Zhongyi S., Chunhui Z., Changshi X., Qianqian C., Dong H., Yimeng Z.** (2020). Automatic ship route design between two ports: A data-driven method, *Applied*

Ocean Research, 96, 102049, 0141-1187, doi: 10.1016/j.apor.2019.102049.

Zhen G., Bin Y., Mengyan H., Wensi W., Yu J., Fang Z. (2021). A novel hybrid method for

flight departure delay prediction using Random Forest Regression and Maximal Information Coefficient, *Aerospace Science and Technology*, 116, 106822, 1270-9638, doi: 10.1016/j.ast.2021.106822.

Araştırma Makalesi

Elektrikli araç şarj istasyonlarının çok kriterli karar verme yöntemleri ile optimal konumlandırması

Melike Sultan Karasu Asnaz^{1,*}, Beyza Özdemir²

^{1,2}Department of Industrial Engineering, Faculty of Engineering, Balıkesir University, Balıkesir, Turkey

*Correspondence: karasu@balikesir.edu.tr

DOI: 10.51513/jitsa.1015108

Özet: Akıllı şehirlerin şekillendirilmesinde ulaşım sektörü önemli bir rol üstlenmektedir. Artan çevre bilinci ve fosil yakıtların tükenmesi sebebiyle ulaştırma sektöründe elektrikli araçların (EV) kullanımı hızla artmaktadır. Karbonsuz bir gelecek projeksiyonunda yollardaki EV sayılarının artması kadar iyi planlanmış ve konumlandırılmış şarj istasyonlarının yapılandırılması da önemli bir gündemdir. Ayrıca EV'ler normal araçlara göre daha uzun şarj olma sürelerine sahiptir. Metropol hayatı ve yoğun yaşam düzeni ile birlikte insanların uzun şarj sürelerine ayıracak vakti olmayacaktır. Bu sebeple şarj istasyonlarının doğru yerlere konumlandırılması ve dahası araç, şarj operatörü ve elektrik dağıtım şirketinin veri bağlantıları aracılığıyla bağlanmasını sağlayan akıllı şarj sistemi ile donatılması gerekmektedir. Bu çalışmada, EV'lere yönelik şarj istasyonu altyapısı planlaması üzerine odaklanılmış ve Balıkesir Üniversitesi Çağış Kampüsü uygulama modeli olarak kullanılmıştır. Öncelikle, araç giriş çıkışlarına dair veriler elde edildikten sonra, sürücülerin kullanım alışkanlıklarına dair anket yapılmıştır. Elde edilen anket verileri değerlendirilmiş ve kampüse yerleştirilecek optimum sayıdaki şarj istasyon sayısı kuyruk teorisi (QT) ile tespit edilmiştir. Kampüs içindeki otoparklar, şarj istasyonlarının yerleştirileceği alanlar olarak belirlenmiştir. Otoparklara dağıtım ise çok kriterli karar verme (ÇKKV) metodları ile çözümlenmiştir. Otopark doluluk oranları, otopark kapasiteleri, trafo merkezine uzaklık gibi kriterler belirlenmiş ve bu kriterlerin önceliklerinin belirlenmesi için Bulanık Analitik Hiyerarşi Prosesi (FAHP) kullanılarak kriterler önceliklerine göre sıralanmıştır. Her bir alternatif konumun kriterlere göre performansı değerlendirilerek, alternatiflerin sıralanması FAHP, The Preference Ranking Organization Method for Enrichment Evaluation (PROMETHEE) ve Simple Multi Attribute Rating Technique (SMART) yöntemleri ile ayrı ayrı yapıldıktan sonra elde edilen sonuçlar karşılaştırılmıştır.

Anahtar Kelimeler: Elektrikli araçlar, şarj istasyonu konumlandırma, kuyruk teorisi, çok kriterli karar verme, FAHP, SMART, PROMETHEE.

Optimal placement of electric vehicle charging stations with multi-criteria decision-making methods

Abstract: The transportation sector plays an important role in shaping smart cities. Due to increasing environmental awareness and depletion of fossil fuels, the use of electric vehicles (EV) in the transportation sector is increasing rapidly. In the projection of a carbon-free future, the structuring of well-planned and positioned charging stations is as important as the increase in the number of EVs on the roads. In addition, EVs have longer recharge times than regular vehicles. With metropolitan life and busy lifestyle, people will not have time to spare for long charging times. For this reason, charging stations should be located in the right places and moreover, they should be equipped with a smart charging system that enables the vehicle, charging operator and electricity distribution company to be connected via data connections. In this study, we focused on charging station infrastructure planning for EVs and Balıkesir University Çağış Campus was used as an application model. First of all, the number of incoming and outgoing vehicles obtained, a survey was conducted on the driving habits of the drivers. The obtained survey data were evaluated and the optimum number of charging units to be

* Corresponding author.

E-mail address: karasu@balikesir.edu.tr

Received 26.10.2021; accepted 30.11.2021

Peer review under responsibility of Bandirma Onyedi Eylül University.

placed on the campus was determined by queuing theory (QT). Parking lots within the campus are designated as areas where charging units will be placed. Distribution to the parking lots was solved with multi-criteria decision making (MCDM) methods. Criteria such as parking occupancy rates, parking capacities, distance to the transformer center were determined and the criteria were ranked according to their priorities by using the Fuzzy Analytical Hierarchy Process (FAHP) to determine the priorities of these criteria. The performance of each alternative location was evaluated according to the criteria, and the results were compared after ranking the alternatives separately with FAHP, The Preference Ranking Organization Method for Enrichment Evaluation (PROMETHEE) and Simple Multi Attribute Rating Technique (SMART).

Keywords: Electric vehicles, charging station placement, queuing theory, multi-criteria decision analysis, FAHP, SMART, PROMETHEE.

* Corresponding author.

E-mail address: karasu@balikesir.edu.tr

Received 26.10.2021; accepted 30.11.2021

Peer review under responsibility of Bandirma Onyedi Eylul University.

1. Giriş

20. yüzyılın sonlarında ortaya çıkan dünya enerji krizi ve küresel ısınma bilincinin sürekli yükselmesi nedeniyle sera etkisine sebep olabilecek salınımlarda bulunan içten yanmalı motorlu araçlar gözden düşmeye başlamış ve EV'ler, son yıllarda en umut verici ulaşım alternatiflerinden biri haline gelmiştir. ABD, İngiltere ve Almanya gibi çeşitli ülkelerde pil teknolojileri ve şarj istasyonu altyapılarına yapılan yatırımlar e-mobilitenin yükselişte olduğunu göstermektedir (Wagner vd., 2013).

Birçok ülke yakın gelecekte yollarına büyük miktarlarda EV getirmeyi planlasa da ön koşul olarak bu araçlara elektrik sağlamak için yeterli bir şarj altyapısına ihtiyaç duymaktadır (Xylia vd., 2017). Akıllı şehirlerde EV'lerin günlük yaşama entegre edilebilmesi için akademi camiası ve şehir planlamacılar birçok çalışma yapmaktadır. Harighi (2019), EV'lerin yaygınlaşmasıyla şarj istasyonlarının konumlanmasının elektrik dağıtıcıları için önemli bir problem olduğunu vurgulamaktadır. Çalışmada, transformatörlerin konumlarına göre, EV'ler için şarj istasyonlarının konumlandırılması senaryosu oluşturmuş ve şebeke altyapısının bazı özelliklerine göre; konum bulma, transformatörlerin kapasitesini sınıflandırma ve transformatör analizi bölümlerinden oluşan özgün çözüm algoritmaları sunmuştur. Elektrik tüketim miktarını algoritmasına entegre ederek daha sonra olası istasyonların konumlarını tanımlamıştır. Awasthi vd. (2017) çalışmalarında, şarj istasyonlarının optimum konumlandırılmasını çözmek için genetik ve parçacık sürüsü optimizasyon algoritmasına dayalı bir hibrit algoritma uygulamışlardır. Sonuçlar toplandıktan sonra altyapı, simülasyonda gerçek zamanlı sistemle test edilmiştir. Xylia vd. (2017), Stockholm'de kullanılan elektrikli otobüsler için şarj altyapısını optimize etmek ve ulaşım maliyetlerini en aza indirmek için karmaşık tam sayılı doğrusal programlama kullanarak toplu taşıma yatırımları için karar vermede yardımcı olabilecek bir model sunmuşlardır. Micari vd. (2017), İtalya'daki tüm karayolu ağını kapsayan hem EV şarj istasyonlarının optimal sayısını hem de konumunu hesaplamak için iki aşamalı bir metodoloji geliştirmişlerdir. İlk aşamada şarj istasyonlarının optimal konumlandırılması için otonom araç ve menzil kaygısı parametreleri kullanılırken, ikinci aşamadaki

optimal şarj istasyonu sayısı içinse amplifikasyon faktörü, şarj soketi sayısı, günlük şarj edilebilen araç sayısı gibi parametreler ele alınmıştır.


Konum belirleme gibi birden çok alternatifin olduğu ve karar vericinin birden fazla kriteri birlikte değerlendirmesi gerektiği problemlerde ÇKKV yöntemleri kullanılmaktadır. Küçüköğlü (2020), Türkiye'de nükleer enerji santrali kuruluş yerini belirlemek için AHP, ELECTRE ve PROMETHEE yöntemleri uygulamıştır. Kırçalı (2019), çalışmada, güneş tarlası kurulumu için en uygun sahanın seçilebilmesi için uzaktan algılama ve coğrafi bilgi sistemleri teknolojilerinden yararlanılmış ve ÇKKV yöntemlerinden olan AHP tekniği kullanılarak uygun sahanın seçimini yapmıştır. Avdan (2018), Türkiye'de e-atık kazanım tesisi için kuruluş yeri belirlemede Türkiye'deki kentler için, Gri İlişkisel Analiz tekniğini uygulayarak bir e-atık geri kazanım tesisinin kurulumu için en iyi yer seçimi çalışmasını gerçekleştirmiştir.

Bu çalışma, EV şarj istasyonlarının ÇKKV metotları ile optimal konumlandırılması üzerinedir ve Balıkesir Üniversitesi Çağış Yerleşkesinde bulunan araç ve kullanıcı verileri ile gerçekleştirilmiştir. Çalışma iki kısımdan oluşmaktadır. İlk kısmı, kampüsteki mevcut otoparklara kurulması planlanan EV şarj istasyonlarının toplam sayısını hesaplamaktır. Bunun için anket sonuçlarından elde edilen veriler doğrultusunda kullanıcı deneyiminin en iyi düzeyde sağlanması için minimum kuyrukta bekleyen araç sayısı kısıtı dikkate alınarak QT metodu ile optimal şarj istasyon sayısı tespit edilmiştir. İkinci kısım ise belirlenen toplam EV şarj istasyonlarının otoparklara olan dağılımıyla ilgilidir. Bu problem bir kara verme problemi olarak değerlendirilmiş ve ÇKKV metotlarından olan FAHP, PROMETHEE ve SMART kullanılarak üç farklı yöntemle şarj istasyonlarının optimal konumlandırılması yapılmış ve sonuçlar karşılaştırılmıştır.

2. Materyal ve Metot

2.1 Sarj İstasyon Sayısının Belirlenmesi: Kuyruk Teorisi

Çalışma, dokuz trafo merkezi ve on sekiz otoparka sahip Balıkesir Üniversitesi Çağış Yerleşkesinde gerçekleştirilmiştir. Kampüste bulunan ana giriş kapısından bir hafta boyunca özel araç giriş-çıkış verileri temin edilmiştir.



Şekil 1. M/M/s kuyruk modeli

Ayrıca öğrencilere, akademisyenlere ve idari personele uygulanan anket ile sürücülerin en sık kullandıkları otoparklar ve araçların ortalama park halinde kalma süreleri verileri elde edilmiştir.

Çalışmanın ilk kısmı olan optimal şarj istasyon sayısını tespit edebilmek için QT'den faydalanılmıştır. Ele alınan modelde servis sağlayıcısı olan şarj istasyonu tek faz/tek sıra/çoklu sunucu (M/M/s) olup model Şekil 1'de gösterilmiştir.

Çalışmada yapılan modele ait kabuller şöyledir;

1. Araçların gelişi poisson dağılımına uygundur (her sürücü davranışı birbirinden farklı ve bağımsız olarak ele alınır) (Wang vd., 2010).
2. Araçlar tek bir sıra oluşturur ve sisteme giriş anları farklıdır.
3. Araç sürücüleri kuyruğa girmeye razı olup herhangi bir anda kuyruğu terk etme eğilimi göstermezler.
4. Bütün şarj istasyonlarının verimleri aynıdır.

(M/M/s) modeline ait sistem yoğunluğu (ρ) hesaplaması Denklem (1)'deki gibidir;

$$\rho = \frac{\lambda}{s\mu} \quad (1)$$

Burada λ birim zamanda giriş yapan ortalama araç yoğunluğunu, s servis sağlayacak şarj istasyonu sayısını, μ ise bir aracın ortalama şarj olma zamanını ifade eder. Servis sağlayıcılarının herhangi bir anda boş olma olasılığı ise Denklem (2)'de verilmiştir.

$$P_0 = \left[\left(\sum_{n=0}^{s-1} \frac{\left(\frac{\lambda}{\mu}\right)^n}{n!} \right) + \frac{\left(\frac{\lambda}{\mu}\right)^s}{s!} \left(\frac{1}{1-\rho} \right) \right]^{-1} \quad (2)$$

P_0 , sistemde hiç araç bulunmama olasılığını gösterir. Kuyruktaki servis almayı bekleyen araç sayısı (L_q) Denklem (3)'teki gibi hesaplanır;

$$L_q = \frac{P_0 \left(\frac{\lambda}{\mu}\right)^s \rho}{s!(1-\rho)^2} \quad (3)$$

Kuyruktaki ortalama bekleme süresi olarak gösterilen W_q değeri ise Denklem (4)'teki gibi hesaplanır;

$$W_q = \frac{L_q}{\mu} \quad (4)$$

Sistemde geçirilen ortalama toplam süre (W) (kuyruktaki bekleme süresi + şarj süresi) ise Denklem (5)'teki gibidir;

$$W = W_q + \frac{1}{\mu} \quad (5)$$


Sistemde bulunan toplam ortalama araç sayısı (L) ve kuyruk sisteminde herhangi bir anda n sayıda araç bulunma olasılığı (P_n) ise sırasıyla Denklem (6) ve (7) ile hesaplanır.

$$L = \lambda W \quad (6)$$

$$P_n = \begin{cases} \frac{\left(\frac{\lambda}{\mu}\right)^n}{n!} P_0; n \leq s \\ \frac{\left(\frac{\lambda}{\mu}\right)^n}{s!s^{n-s}} P_0; n > s \end{cases} \quad (7)$$

Kurulan bu kuyruk modeline göre, sistem içindeki kuyruk uzunluğunun sürekli artmaması yani EV'lerin şarj olmak için istasyonda hizmet sırası beklememesi için $(s\mu)/\lambda > 1$ eşitsizliğinin sağlanması gereklidir.

Personel, öğrenci ve misafirlerin kampüse giriş ve çıkışları tek bir ana kapıdan, bariyer kapı geçiş sistemi ile yapılmaktadır. Güvenliğin de bulunduğu bu kapıda kimlik kartlarıyla giriş yapılmaktadır, ayrıca araç plakalarının ve giriş saatlerinin de kaydedildiği bir otomasyona sahiptir. Kampüse giren araç yoğunluğunu belirleyebilmek için bu kapıdan toplanan veri ele alınmıştır. Verinin gerçek durumu yansıtması için araç giriş-çıkışın az olduğu tatil dönemleri ve araç giriş-çıkışının yoğun olduğu sınav dönemleri dikkate alınmamıştır. 16-22 Aralık 2019 tarihleri arasında kaydedilen bir haftalık veriye göre kampüse günlük giriş yapan özel araç yoğunluğu değişimi Şekil 2'de gösterilmiştir. Buna göre kampüse en fazla giriş yapılan gün ve saat dilimi referans alınmıştır. Yağcıtekin (2014), 2020 yılı iyimser senaryolarında bir otoparktaki tüm araçların ortalama %5'inin elektrikli olabileceğini ifade etmiştir. Bu yüzden bu çalışmada otoparktaki tüm araçların %5'nin elektrikli olması ile şarj servisi almak isteyen araçların kuyruktaki minimum bekleme süresi durumları dikkate alınarak MATLAB programında hesaplamalar yapılmıştır.



Şekil 2. Günlük giriş yapan araç yoğunluğu değişimi.

Sistem yoğunluğu (ρ) ile birim zamanda ortalama giriş yapan araç yoğunluğunu (λ) ölçebilmek için Google Forms üzerinden sürücü davranışlarını anlamaya yönelik bir anket hazırlanmış ve dağıtılmıştır. Katılımları için öğrencilere, akademik ve idari personele kurumsal e-posta adreslerinden ulaşılmıştır. Bir hafta süreyle çevrimiçi yapılan ankete toplamda

136 kişi cevap vermiştir. Dört sorudan oluşan bu ankette (i) kişilerin kampüse ulaşımını nasıl sağladıkları, (ii) günlük ortalama kaç km mesafe kat ettikleri, (iii) kampüs içindeki hangi otoparkı en sık kullandıkları ve (iv) günlük ortalama ne kadar süre ile araçlarını otoparkta bıraktıkları sorulmuştur. 89 katılımcı kampüse ulaşımını özel araçları ile sağladığını ifade ederken, günde en az bir otoparkı kullandıklarını belirtmişlerdir. Anket sonucuna göre kullanıcıların çoğu günde 6 ila 9 saat araçlarının park halinde kaldığını belirtmişlerdir. Anketten elde edilen veriler doğrultusunda özel araçla kampüse ulaşan sürücülerin en sık kullandığı otoparklar tespit edilmiş ve araçların otoparkta kalma süreleri dikkate alınarak sistemde en az bekleme süresini sağlayan optimal şarj istasyonu sayısı belirlenmiştir.

Bunun içinse şarj istasyonunu, tek faz/tek sıra/çoklu sunucu (M/M/s) olarak kabul eden QT modeli kurulmuş ve buna göre bir aracın servis almak için en az bekleme süresini sağlayan toplam şarj istasyonu sayısı tüm kampüs otoparkları için 70 adet olarak hesaplanmıştır.


2.2. Sarj İstasyonlarının Dağılımı: Çok Kriterli Karar Verme Yöntemi

ÇKKV yöntemi, alternatifin performansını çok sayıda, çelişkili, niteliksel ve/veya niceliksel kriterler arasında birleştiren ve fikir birliği gerektiren bir çözümle sonuçlanan bir tekniktir. ÇKKV'nin amacı en iyi kararı önermek değil, karar vericilere kısa listeye alınmış alternatifleri veya gereksinimlerini karşılayan ve tercihleriyle uyumlu tek bir alternatifi seçmede yardımcı olmaktır (Kırcalı, 2019). Bu bölümde, üç farklı ÇKKV yöntemi kullanılarak 70 adet şarj istasyonunun kampüs içindeki 12 otoparka belirlenen kriterler doğrultusunda optimal dağılımı çalışması yapılmıştır.

Kampüste bulunan tüm otoparklar şarj istasyonlarının yerleşimi için alternatif yer olarak tanımlanmıştır. Sürücü profillerinin değerlendirilmesinde anketten faydalanılmış ve elde edilen sonuçlara göre en az tercih edilen ve hiç tercih edilmeyen bazı otoparklar çalışmaya dahil edilmemiştir. Tablo 1'de problem alternatifleri olarak tanımlanan otoparklar ve kapasiteleri verilmiştir.

Alternatiflerin sayısal analizini içeren herhangi bir karar verme tekniğinin kullanılmasında üç

işlem vardır; (i) ilgili kriterleri ve alternatifleri belirlemek, (ii) hem kriterlerin göreceli önemine hem de alternatiflerin bu kriterler üzerindeki etkilerine istatistiksel ölçümler eklemek ve (iii) her bir alternatifi sıralamak (Patel vd., 2017). ÇKKV'de genel işleyişi gösteren akış şeması Şekil 3' teki gibi gösterilebilir.



Şekil 3. ÇKKV'de Karar Verme Süreci

Karar verme probleminin diğer bir bileşeni olan kriterler belirlenirken literatürden faydalanılmış ve probleme uygun dört kriter belirlenmiştir. Bu çalışmada ele alınan kriterler (Cn) şöyledir;

1. *Otopark Araç Kapasitesi (C1)*: Gelecekteki EV ve sürücü yoğunluğu artışına dikkate alınır.
2. *Tercih Edilirlik (C2)*: İnsan yoğunluğu fazla olan noktalar daha çok kullanımı olan ve yürüme mesafesini kısaltacağı için en tercih edilen noktalar olacaktır. Bu yüzden yoğunluğunun fazla olduğu otoparkların daha fazla şarj istasyonuna ihtiyacı olacağı dikkate alınır.
3. *Değişkenliğe Duyarlılık (C3)*: Ziyaretçisi değişken olan (Rektörlük, Teknokent gibi) konumların doluluk oranlarının değişken olacağı düşünülmüş ve bu sebeple şarj istasyon sayısının anket sayısına göre belirlenecek sayıdan daha fazla olabileceği dikkate alınmıştır.
4. *Otoparkın Trafo Merkezi ile Arasındaki Uzaklık (C4)*: Enerjideki düşük kalitenin önüne geçmek, yatırım maliyetlerini ve enerji kayıplarını azaltmak için uzaklık dikkate alınır.

Kampüs içindeki mevcut otoparklar (P) ve trafo merkezlerinin (T) yerleşimi Şekil 4'te verilmiştir.

2.2.1. Kriter ağırlıklarının belirlenmesi

Karar verme sürecinde karşılaşılan soyut kavramlar günlük hayatta karar vermeyi büyük bir belirsizliğe yöneltmektedir. Bu belirsizlik anlarında karar verebilme sürecini yönetebilmek için, çeşitli çözüm yolları önerilmiş ve bulanık mantık fikri ortaya sürülmüştür. FAHP yöntemi bunlardan biridir ve bu yöntemde, uzman görüşünün kesin sayılar yerine bulanık sayılarla temsil edilmesi gerekir.

Tablo 1. Alternatifler ve kapasiteleri

Otoparklar	Alternatif Adı	Kapasite
Mühendislik Fakültesi Ek Bina	P1	62
Fen Edebiyat Fakültesi	P2	174
Mühendislik Fakültesi Ana Bina	P3	240
Turizm Fakültesi	P4	74
Veterinerlik Fakültesi	P5	94
Rektörlük Binası	P6	150
Sağlık Bilimleri Fakültesi	P7	160
Meslek Yüksek Okulu	P8	191
İktisadi ve İdari Bilimler Fakültesi	P9	65
Spor Bilimleri	P10	139
Residorm Yurtları	P11	77
Teknokent	P12	70



Şekil 4. Kampüs otopark ve trafo merkezlerinin genel görünümü.

Çalışmada kriter ağırlıklarının belirlenebilmesi için Tablo 2'deki gibi ifade edilen üçgen bulanık sayılar kullanılmıştır. Bu sayılar (l, m, u) parametreleri ile ifade edilir ve sırasıyla bulanık bir miktarı tanımlayan olası en küçük değeri, en umut verici değeri ve mümkün olan en büyük değeri ifade eder (Soltani ve Marandi, 2011). Çalışma özelinde FAHP hiyerarşi yapısı Şekil 5'te gösterilmiştir.

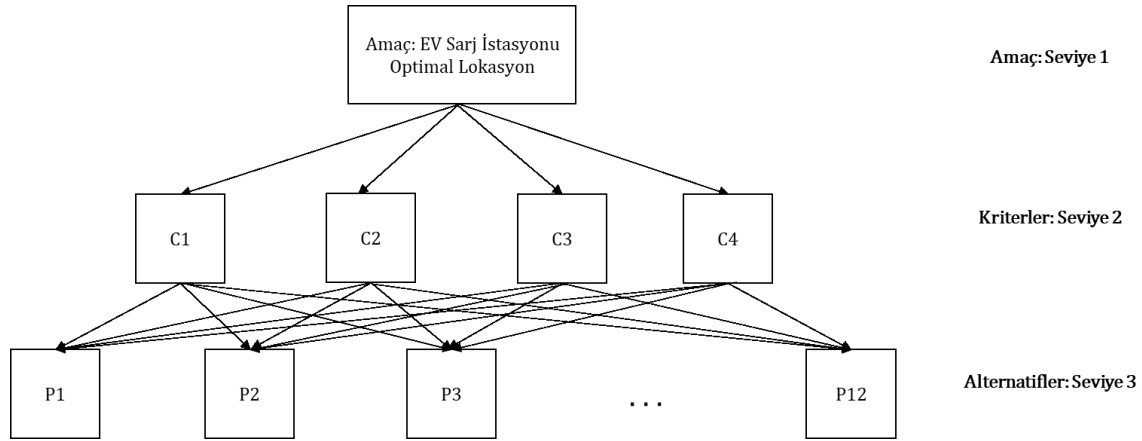
Belirlenen 70 adet şarj istasyonunun dağıtımının yapılması için sürücülerin fikirleri dikkate alınmış ve sözel mantıkla ifade

edilebilen bulanık sayılardan yararlanılarak çözüm gerçekleştirilmiştir. Karar vericiler tarafından FAHP ile kriterlerin ağırlık değerlendirmeleri yapılmış ve bu kriterler Tablo 2'de gösterilen bulanık sayılarla değerlendirilmiştir. Ardından ikili karşılaştırma yapmak için üçgensel bulanık karşılaştırma matrisi Denklem (8)'deki gibi tanımlanmıştır.

$$a_{ij} = \begin{pmatrix} (111) & (l_{12}m_{12}u_{12}) & \dots & (l_{14}m_{14}u_{14}) \\ \dots & \dots & \dots & \dots \\ (l_{41}m_{41}u_{41}) & (l_{42}m_{42}u_{42}) & \dots & (111) \end{pmatrix} \quad (8)$$

Tablo 2. Dilsel ölçek ve bulanık sayılar (Rajabi vd., 2018)

Dilsel Ölçek	Bulanık Ölçek	Karşılık Ölçek
Kesin eşit	(1,1,1)	(1,1,1)
Eşit derece önemli	(1/2, 1, 3/2)	(2/3, 1, 2)
Biraz daha önemli	(1, 3/2, 2)	(1/2, 2/3, 1)
Kuvvetli derecede önemli	(3/2, 2, 5/2)	(2/5, 1/2, 2/3)
Çok kuvvetli derecede önemli	(2, 5/2, 3)	(1/3, 2/5, 1/2)
Tamamıyla önemli	(5/2, 3, 7/2)	(2/7, 1/3, 2/5)



Şekil 5. FAHP hiyerarşi yapısı (Afolayan vd. (2020)'den uyarlanmıştır)

Tablo 3. Kriter karşılaştırma matrisi

	C1			C2			C3			C4		
	<i>l</i>	<i>m</i>	<i>u</i>	<i>l</i>	<i>m</i>	<i>u</i>	<i>l</i>	<i>m</i>	<i>u</i>	<i>l</i>	<i>m</i>	<i>u</i>
C1	1,00	1,00	1,00	0,90	1,44	1,95	0,63	1,14	1,65	0,90	1,44	1,95
C2	0,51	0,69	1,10	1,00	1,00	1,00	1,14	1,71	2,24	1,65	2,15	2,65
C3	0,60	0,87	1,58	0,44	0,58	0,87	1,00	1,00	1,00	1,00	1,50	2,00
C4	0,51	0,69	1,10	0,37	0,46	0,60	0,50	0,66	1,00	1,00	1,00	1,00

1

Buckley (1985)'in önerdiği gibi karar vericilerin bulanık değerlendirmeleri alındıktan sonra ikili karşılaştırmaların geometrik ortalaması alınarak kriter karşılaştırma matrisi hesaplanmıştır ve bu değerler Tablo 3'te gösterilmiştir.

Son aşamada ise elde edilen bulanık kriter ağırlıklarının en iyi bulanık olmayan performans değerleri hesaplanmıştır. Durulaştırma olarak ifade edilen bu işlem Denklem (9)'da gösterilen alan merkezi (*center of area*) yöntemi ile hesaplanmıştır.

$$COA_{w_i} = \frac{[(u_{wi} - l_{wi}) + (m_{wi} - l_{wi})]}{3} + l_{wi} \quad (9)$$

Sonuç olarak yapılan FAHP ile kriter ağırlıklandırma işlemine göre en yüksek öneme sahip kriter C2, yani tercih edirlilik kriteri olarak belirlenirken, en az öneme sahip kriter

ise C4, yani otopark ve trafo merkezi arasındaki mesafe kriteri olmuştur. Nihai karar matrisi ise Tablo 4'te sunulmuştur.

Tablo 4. Nihai karar matrisi

	C1	C2	C3	C4
Ağırlık	0,313	0,347	0,259	0,183
Sıralama	2	1	3	4

2.2.2 FAHP ile Konumlandırma

FAHP ile kriter ağırlıkları belirlendikten sonra her bir kriter için alternatiflerin ağırlıklarının belirlenmesi yapılmıştır. Tüm alternatiflerin kriterlere göre değerlendirildiği nihai karar matrisi tabloları tüm kriterler için hesaplanmış ve Tablo 5'te gösterilmiştir. Ardından Tablo 4'te yer alan kriter ağırlık değerlerinden yararlanılarak her bir otopark için nihai karar matrisi değeri ile kriter ağırlık değeri çarpılarak toplam skorlar hesaplanmış ve yine Tablo 5'te gösterilmiştir.

Tablo 5. Tüm kriterlerin nihai karar matrisleri ve alternatiflerin toplam skor tablosu

	C1	C2	C3	C4	Toplam Skor	Sıralama
P1	0,082	0,127	0,097	0,117	0,12	5
P2	0,139	0,138*	0,099	0,119	0,14	1
P3	0,141*	0,114	0,101	0,133*	0,13	2
P4	0,086	0,12	0,103	0,074	0,11	7
P5	0,089	0,068	0,105	0,094	0,10	9
P6	0,106	0,069	0,147*	0,133*	0,12	4
P7	0,118	0,09	0,109	0,078	0,11	6
P8	0,13	0,108	0,111	0,103	0,13	3
P9	0,058	0,1	0,113	0,063	0,09	10
P10	0,089	0,071	0,115	0,106	0,10	8
P11	0,063	0,047	0,115	0,063	0,06	12
P12	0,056	0,044	0,11	0,104	0,08	11

Tablo 6. FAHP yöntemi ile otoparklara göre şarj istasyonu dağılımı

Otoparklar	Şarj İstasyonu Sayısı
P1	6
P2	8
P3	7
P4	6
P5	5
P6	7
P7	6
P8	7
P9	5
P10	6
P11	3
P12	4

Burada toplam skor, ait olduğu alternatife ne kadar şarj istasyonu atanması gerektiğini belirten bir değerdir. Bu bağlamda hesaplanan 70 adet şarj istasyonu Tablo 6'daki gibi alternatiflere dağıtılmıştır.

2.2.2. PROMETHEE ile Konumlandırma

PROMETHEE, tanımlanan kriterler içinde en iyi alternatifin belirlenebilmesi için kullanılan ÇKKV yöntemlerinden biridir. Bu yöntem, literatürde uygulamasına sık rastlanılan önceliklendirme metodlarının uygulanmasındaki zorlukları aza indirmek ve öznellikten arındırmak için geliştirilmiştir (Genç ve Urfalıoğlu, 2013).

Bu yöntemde kriterler, fayda ve maliyet olarak ele alınır. Buna göre bu çalışmada C1, C2, C3 fayda kriterleri, C4 ise maliyet kriteri olarak

belirlenmiştir. Buna göre fayda ve maliyet kriterleri için sırasıyla Denklem (10) ve (11) kullanılarak normalizasyon gerçekleştirilir. i kriterler ($i=1,2,\dots,n$); j , alternatifler ($j=1,2,\dots,m$); A satır ve x sütun değerleri olmak üzere Tablo 7'deki karar matrisi elde edilmiştir.

$$C_{ij} = \frac{x_{ij} - \min(x_{ij})}{\max(x_{ij}) - \min(x_{ij})} \text{ (fayda)} \quad (10)$$

$$C_{ij} = \frac{\max(x_{ij}) - x_{ij}}{\max(x_{ij}) - \min(x_{ij})} \text{ (maliyet)} \quad (11)$$

C_{ij} değerlerinin hesaplanmasının ardından $P_i(A, x)$ olarak ifade edilen tercih edilebilirlik fonksiyonları belirlenmiş ve Denklem (12) ile hesaplanmıştır.

Tablo 7. Karar matrisi

	C1	C2	C3	C4
P1	62	3098	1	134,52
P2	174	3779	1,02	125,96
P3	240	1640	1,04	81,62
P4	74	1931	1,06	393,84
P5	94	285	1,07	169,06
P6	150	388	1,55	68,96
P7	160	1000	1,11	203,79
P8	191	6333	1,13	131,13
P9	65	1926	1,15	248,36
P10	139	975	1,17	83,62
P11	77	116	1,17	224,08
P12	70	160	1,12	44,35

$$\pi(A, x) = \sum_{i=1}^n (w_i P_i(A, x)) \quad (12)$$

Burada $\pi(A, x)$, A'nın hangi derecede x 'e göre tercih edildiğini ifade etmektedir. Tercih indeksleri belirlendikten sonra Denklem (13) ile Pozitif (Φ^+) ve Negatif (Φ^-) üstünlük tanımlamalarını yapılır ve bu işlem, tüm alternatifler için hesaplanır.

$$\Phi^+(A) = \frac{1}{m-1} \sum_{x \in A} \pi(A, x) \text{ ve}$$

$$\Phi^-(A) = \frac{1}{m-1} \sum_{x \in A} \pi(x, A) \quad (13)$$

Pozitif üstünlük, $\Phi^+(A)$, her bir alternatifin diğer alternatiflere göre toplu bir sıralama ölçütüdür, kısaca diğer alternatifleri nasıl geride bıraktığını gösterir. Negatif üstünlük, $\Phi^-(A)$, ise diğer alternatifler tarafından nasıl domine edildiğini gösterir.

Son olarak her bir alternatif için net üstünlük değeri Denklem (14) ile hesaplanır.

$$[\Phi(A_{net}) = \Phi^+(A) - \Phi^-(A)] \quad (14)$$

Bir karar için net üstünlük değeri ne kadar yüksekse, karar o kadar iyidir. Bu problemde, verilecek en iyi karar dikkate alınacağı için, net üstünlük değeri maksimize eden kararı seçilmiştir. Bu hesaplamalara göre 70 adet şarj istasyonu Tablo 8'de gösterilen şekilde alternatiflere dağıtılmıştır.

Tablo 8. PROMETHEE yöntemi ile otoparklara göre şarj istasyonu dağılımı

Otoparklar	Şarj İstasyonu Sayısı
P1	4
P2	11
P3	12
P4	0
P5	2
P6	4
P7	6
P8	17
P9	3
P10	7
P11	1
P12	3

2.2.3. SMART ile Konumlandırma

SMART yöntemi çok kriterli fayda teorisi yöntemlerinden biridir, fayda ve maliyet

unsurlarını dikkate alarak kriterlerin performans değerlerine göre hesaplamalar yapılır (Arslan, 2019). SMART'ta alternatiflerin derecelendirmeleri doğrudan atanır. Kriterlerin ağırlığını ve alternatiflerin derecesini mümkün olduğunca ayrı tutmak için, farklı kriter ölçeklerinin standart bir dahili ölçüğe dönüştürülmesi gerekir. Bu teknikteki süreç, bir değer fonksiyonu kullanılarak karar verici tarafından matematiksel olarak yapılır. Bir değer fonksiyonu yönteminin en yaygın olarak kullanılan biçimi toplamsal modeldir (Patel vd., 2017) ve bu çalışmada da bu yöntem uygulanmıştır.

Bu yöntemin çözümünde PROMETHEE'de olduğu gibi Tablo 4'te yer alan kriter ağırlıkları ve Tablo 7'de yer alan karar matrisi kullanılmıştır. Fayda ve maliyet kriterleri için sırasıyla,

$$C_{ij} = \frac{x_{ij}}{\max(x_{ij})} \text{ (fayda)} \quad (15)$$

$$C_{ij} = \frac{x_{ij}}{\min(x_{ij})} \text{ (maliyet)} \quad (16)$$

Denklem (15) ve (16) kullanılarak değerler normalize edilmiştir ve ardından, alternatiflerin puanını temsil eden değer fonksiyonu ve toplam ağırlıklı puanı gösteren P , Denklem (17)'deki gibi hesaplanmıştır. Burada; w_j , normalize edilmiş ağırlık olup x_{ij} niteliğinin ağırlığını ifade eder, r_{ij} ise, karar vericiler tarafından atanan özelliğin değeridir (Chen vd., 2010).

$$P = \sum_{i=1}^n w_j r_{ij} \quad (17)$$

Bulunan genel fayda değerleri Tablo 9'da gösterilmiştir ve 70 adet şarj istasyonu Tablo 10'da gösterilen şekilde alternatiflere dağıtılmıştır.

Tablo 9. Genel fayda değerleri

	C1	C2	C3	C4	P
P1	1346	1734	1,62	0,536	0,529
P2	1859	1857	1628	0,542	0,797
P3	2056	1391	1636	0,587	0,718
P4	1422	1472	1644	0,44	0,396
P5	1533	0,758	1648	0,514	0,257
P6	1774	0,844	1814	0,605	0,43
P7	1811	1172	1664	0,497	0,458
P8	1914	2221	1672	0,538	1

Tablo 9 (devamı). Genel fayda değerleri

P9	1366	1,47	1679	0,479	0,422
P10	1733	1161	1687	0,585	0,519
P11	1,44	0,555	1687	0,488	0,172
P12	1398	0,621	1668	0,656	0,248

Tablo 10. SMART ile otoparklara göre şarj istasyonu dağılımı

Otoparklar	Şarj İstasyonu Sayısı
P1	6
P2	9
P3	8
P4	5
P5	3
P6	5
P7	5
P8	12
P9	5
P10	6
P11	3
P12	3

3. Bulgular ve tartışma

Çalışmada, ÇKKV metotlarından FAHP, PROMETHEE ve SMART ile şarj istasyonlarının optimal noktalara yerleştirilmesi için karşılaştırılmalı çözüm önerileri sunulmuştur. Bu amaçla Balıkesir Üniversitesi Çağış Yerleşkesi model olarak kullanılmıştır. EV'lerin kuyrukta minimum bekleyecek şekilde şarj istasyonlarından servis alabilecekleri bir sistem tasarımı yapılmıştır. Anket verilerinden yararlanılarak ortalama şarj süresi 6 saat, saatlik ortalama en yüksek giriş yapan araç sayısı ise 202 araç olarak saptanmıştır. Bu durumda, otoparktaki tüm araçların %5'inin EV olması durumunda 70 adet şarj istasyonunun yeterli olacağı hesaplanmıştır. Daha sonra optimum dağılım yapabilmek için alternatifler ve kriterler oluşturulmuştur. Kriter ağırlıklandırması için karar vericiler tarafından beyan edilen sözel ifadelerin bulanık mantıkla değerlendirilmesi uygun görülmüş ve FAHP ile kriter ağırlıklandırması gerçekleştirilmiştir. Ardından FAHP, PROMETHEE ve SMART teknikleri ile çözümler yapılarak sonuçlar karşılaştırılmıştır.

Tablo 11, tüm çözüm yöntemlerinin otoparklara tayin ettiği şarj istasyonu sayısını

özetlemektedir. Buna göre, FAHP ile yapılan dağıtımın PROMETHEE ve SMART yöntemlerine göre daha dengeli olduğu dikkat çekmektedir. Bunun sebebi FAHP ile yapılan değerlendirmede karar matrisinin yani kriterlere göre alternatiflerin karşılaştırılmasının sözel ifade gibi düşünülerek bulanık mantık ile oluşturulmasıdır. Fakat kriterlere göre alternatiflerin karşılaştırılması için oluşturulan karar matrisi somut sayısal verilerden meydana gelmektedir. Sonuç olarak problem özelinde değerlendirildiğinde PROMETHEE ve SMART yöntemi ile yapılan dağıtım daha tutarlı sonuç vermektedir.

Tablo 11. Şarj istasyonlarının otoparklara dağılımı

Otoparklar	FAHP	PROMETHEE	SMART
P1	6	4	6
P2	8	11	9
P3	7	12	8
P4	6	0	5
P5	5	2	3
P6	7	4	5
P7	6	6	5
P8	7	17	12
P9	5	3	5
P10	6	7	6
P11	3	1	3
P12	4	3	3

4. Sonuç

Günümüzde taşımacılık sektörü büyük ölçüde fosil yakıtlara bağımlıdır ve son yıllarda bu sektörün yarattığı çevre sorunlarına daha fazla önem verilmektedir. Verimliliğinden ödün vermeden ulaşım sisteminde bir değişim zor görünse de EV'lerin hem çevre problemlerini azaltması hem de petrole olan bağımlılığı azaltması nedeniyle yakın gelecekte piyasada çok daha fazla tercih edilecekleri beklenmektedir. Bununla birlikte, EV şarj istasyonları planlarının gelecekteki ihtiyaçları karşılayacak kadar esnek olması önemlidir. Akıllı ve değer odaklı kararlar, fosil yakıt sonrası bir gelecek için EV şarjını mümkün kılmakla kalmaz, aynı zamanda ekonomik büyüme, çevresel hedefler ve bölge sakinleri için hizmetler üzerinde olumlu bir etki yapabilir. Bu yüzden halihazırda devam eden veya planlanan birçok akıllı şehir girişimi

planlarına EV şarj istasyonlarının planlamasını da dahil etmelidir.

Bu öngörüyle, bu çalışma EV şarj istasyonu sayısı belirleme ve bu istasyonların optimal dağılımı üzerine odaklanmıştır. Bu çalışmanın mevcut çalışmalardan farkı ihtiyaçlara göre yatırımcıların/kullanıcıların kolay karar almasına olanak sağlayacak esnek bir yapıda olmasıdır. Bu amaçla, iki optimizasyon yöntemi QT ve ÇKKV birleştirilerek, karar alabilecek ve amaca göre hızlı cevap verebilecek yöntem geliştirilmiştir. QT, şarj altyapısı kurulması planlanan bölgede belirlenen hedeflere göre kaç adet şarj istasyonunun beklentileri karşılayacağına hesaplanması için kullanılırken, üç farklı ÇKKV yöntemi şarj istasyonlarının kampüs içindeki otoparklara dağılımını tayin etmek için kullanılmıştır. Sonuçlara göre PROMETHEE ve SMART ile yapılan dağıtımın FAHP'ye oranla daha tutarlı çözümler ürettiği sonucuna ulaşılmıştır.

Araştırmacıların Katkı Oranı Beyanı

Yazarların çalışmadaki katkı oranları eşittir.

Destek ve Teşekkür Beyanı

Çalışma herhangi bir destek almamıştır. Teşekkür edilecek bir kurum veya kişi bulunmamaktadır.

Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

Kaynakça

Arslan, H. M., (2019). SMART-TOPSIS Hibrit Yöntemi İle Personel Seçimi: Demir-Çelik İşletmelerinde Bir Uygulama: *The 4th In Traders International Conference on International Trade Proceeding Book*, Sakarya, Turkey, 115-126.

Afolayan, A. H., Ojokoh, B. A., Adetunmbi, A. O., (2020). Performance analysis of fuzzy analytic hierarchy process multi-criteria decision support models for contractor selection. *Scientific African*, 9, e00471.

Avdan, E., (2018). Çok Kriterli Karar Verme Teknikleri ile E-Atık Geri Kazanım Tesisi Yer Seçimi. *Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Denizli*, 159 s.

Awasthi, A., Venkitesamy, K., Padmanaban, S., Selvamuthukumar, R., Blaabjerg, F., Singh, A. K., (2017). Optimal Planning of

Electric Vehicle Charging Station at the Distribution System Using Hybrid Optimization Algorithm. *Energy*, 133, 70–78.

Buckley, J., (1985). Fuzzy Hierarchical Analysis. *Fuzzy Sets and Systems*, 9, 471.

Chen, Y., Okudan, G. E., Riley, D. R., (2010). Decision Support for Construction Method Selection in Concrete Buildings: Prefabrication Adoption and Optimization. *Automation in Construction*, 19, 665–675.

Genç, T., Urfaloğlu, F., (2013). Çok Kriterli Karar Verme Teknikleri ile Türkiye' nin Ekonomik Performansının Avrupa Birliği Üye Ülkeleri ile Karşılaştırılması. *M.U. İktisadi ve İdari Bilimler Dergisi*, 35, 329–329.

Kırcalı, Ş., (2019). Çok Kriterli Karar Verme Analizi Kullanılarak CBS Tabanlı Güneş Tarlası Yer Seçimi: Antalya İli Örneği. *Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Ana Bilim Dalı, Antalya*, 81s.

Küçüköğlü, S., (2020). Çok Kriterli Karar Verme Yöntemleri ile Türkiye' de Nükleer Santral Kuruluş Yeri Seçimi. *İstanbul Ticaret Üniversitesi / Sosyal Bilimler Enstitüsü / İşletme Ana Bilim Dalı, İstanbul*, 138s.

Micari, S., Polimeni, A., Napoli, G., Andaloro, L., & Antonucci, V., (2017). Electric Vehicle Charging Infrastructure Planning in a Road Network. *Renewable and Sustainable Energy Reviews*, 80, 98–108.

Patel, M. R., Vashi, M. P., Bhatt, B.V., (2017). SMART- Multi-criteria decision-making technique for use in planning activities. *New Horizons in Civil Engineering (NHCE 2017)*, 1–6.

Rajabi, F., Jahangiri, M., Molaeifar, H., Honarbakhsh, M., Farhadi, P., (2018). Occupational Stress Among Nurses and Pre-Hospital Emergency Staff: Application of Fuzzy Analytic Hierarchy Process (FAHP) Method. *EXCLI Journal*, 17, 808–824.

Soltani, A., Marandi, E. Z., (2011). Hospital Site Selection Using Two-Stage Fuzzy Multi-Criteria Decision Making Process. *Journal of Urban and Environmental Engineering*, 5, 32-43

Wang, Z., Liu, P., Xin, T., (2010). Optimizing the Quantity of Off-Broad Charger for Whole Vehicle Charging Station. *Proceedings - 2010*

International Conference on Optoelectronics and Image Processing, ICOIP 2010, 2, 93–96.

Xylia, M., Leduc, S., Patrizio, P., Kraxner, F., Silveira, S., (2017). Locating Charging Infrastructure for Electric Buses in Stockholm. *Transportation Research Part C: Emerging Technologies*, 78, 183–200.

Yağcıtekin, B., (2014). Elektrikli Araç Şarj Altyapısı Tasarımı ve Akıllı Şarj Sistemin Geliştirilmesi. *Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Ana Bilim Dalı, Elektrik Tesisleri Bilim Dalı, 137s.*